

PCDA-MPAT:物理约束数据增强与多径Transformer的 无源物联网室内定位方法

肖善鹏^{1,2}, 范艺晶^{2*}, 郑师应², 曹艳艳², 王亚敏², 邢 飞¹

(1. 清华大学精密仪器系, 北京 100084; 2. 中国移动通信研究院, 北京 100053)

摘 要: 无源物联网(Ambient Internet of Things, Ambient IoT)室内定位技术在智慧仓储、新零售等场景中具有重要应用价值,但室内复杂多径环境会引发两方面突出问题:一是多径遮挡和标签性能差异导致强弱标签样本严重不平衡,在典型服装陈列场景中,弱标签有效样本量仅为强标签的30%左右;二是多径混叠使信号的位置相关特征区分度显著下降,制约了定位精度的提升。为解决上述问题,本文提出一种融合物理约束数据增强与多径感知Transformer(Physically Constrained Data Augmentation and MultiPath-Aware Transformer, PCDA-MPAT)的定位方法。在数据增强层面,本文提出物理约束的数据增强(Physically Constrained Data Augmentation, PCDA)方法,以相位-频率斜率一致性作为物理约束条件,构建带有梯度惩罚的条件 Wasserstein 生成对抗网络(Wasserstein Generative Adversarial Network with Gradient Penalty, WGAN-GP),生成既匹配实测数据分布又符合无线传播物理特性的弱标签样本,从数据层面有效缓解了强弱标签样本不平衡问题。在模型设计层面,本文构建多径感知Transformer(MultiPath-Aware Transformer, MPAT)定位模型,设计适配静态多径信道衰落特性的时域局部窗口注意力机制,结合时域相对位置编码,捕捉多径特征的时域演化规律,抑制长时域不相关的噪声干扰,增强模型对多径特征的提取与学习能力。在10 m × 10 m的服装陈列场景中开展实测实验,结果表明本文方法的标签级定位准确率达到83.57%,较现有最优基线方法提升5.71个百分点。消融实验进一步验证了PCDA与MPAT的有效性,其中,PCDA使标签级定位准确率提升4.29个百分点,MPAT在此基础上进一步提升2.14个百分点。上述结果验证了本文方法在复杂室内多径环境下的有效性,可满足智慧仓储、新零售等场景的定位需求。

关键词: 无源物联网;室内定位;多径效应;数据增强;生成对抗网络;Transformer

基金项目: 国家科技重大专项(No.2025ZD1301400)

中图分类号: TP391;TP183

文献标识码: A

文章编号: 0372-2112(2026)06-2522-12

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20260456

PCDA-MPAT: Physically Constrained Data Augmentation and Multipath-Aware Transformer for Ambient IoT Indoor Localization

XIAO Shanpeng^{1,2}, FAN Yijing^{2*}, ZHENG Shiyong², CAO Yanyan², WANG Yamin², XING Fei¹

(1. Department of Precision Instrument, Tsinghua University, Beijing 100084, China;

2. China Mobile Research Institute, Beijing 100053, China)

Abstract: Ambient internet of things (Ambient IoT) indoor localization technology holds significant application value in scenarios such as smart warehousing and new retail. However, complex indoor multipath environments give rise to two prominent issues: first, severe imbalance between strong and weak tag samples caused by multipath blockage and tag performance variations. In a typical clothing display scenario, the effective sample size for weak tags is only about 30% of that for strong tags. Second, multipath aliasing significantly degrades the distinguishability of location-dependent signal features, limiting improvements in localization accuracy. To address these issues, this paper proposes a physically constrained data augmentation and multipath-aware transformer (PCDA-MPAT) localization method that integrates physically constrained data augmentation with a multipath-aware Transformer. At the data augmentation level, we propose a physically constrained data augmentation (PCDA) method. Using phase-frequency slope consistency as a physical constraint, we construct a conditional Wasserstein generative adversarial network with gradient penalty (WGAN-GP) to generate weak tag samples that not only match the distribution of measured data but also adhere to the physical laws of wireless propagation, effectively alleviating the imbalance between strong and weak tag samples from the data perspective. At the model design level, we construct a multipath-aware transformer (MPAT) localization model. We design a time-domain local window at-

tention mechanism adapted to the slow-fading characteristics of quasi-static multipath channels, combined with time-domain relative position encoding, to capture the temporal evolution patterns of multipath features, suppress long-term irrelevant noise interference, and enhance the model's ability to extract and learn multipath features. Experimental results in a 10 m×10 m clothing display scenario demonstrate that the proposed method achieves a tag-level localization accuracy of 83.57%, outperforming the best existing baseline method by 5.71 percentage points. Ablation studies further validate the effectiveness of PCDA and MPAT. PCDA alone improves the tag-level localization accuracy by 4.29 percentage points, and MPAT further increases it by 2.14 percentage points. These results confirm the effectiveness of the proposed method in complex indoor multipath environments, meeting the localization requirements of scenarios such as smart warehousing and new retail.

Keywords: ambient IoT; indoor localization; multipath-effect; data augmentation; generative adversarial network; Transformer

Foundation Item(s): National Science and Technology Major Project of China (No.2025ZD1301400)

0 引言

无源物联网 (Ambient Internet of Things, Ambient IoT) 起源于射频识别, 采用反向散射通信机制, 读写节点发射射频载波为无源标签供电, 标签不主动产生射频信号, 而是通过调制和反射入射信号上传信息。该技术因具备低成本、零功耗、易部署的优势, 已发展成为智能仓储管理、工业资产追踪、新零售商品管理等场景的支撑技术, 支撑百亿级物联网连接。其中, 室内定位功能是行业应用对无源物联网提出的重要需求, 其性能水平直接决定了资产管控的精准程度。

室内环境中, 墙体、障碍物和金属货架等反射体会引发严重多径效应, 制约无源物联网定位性能。传统定位方法基于几何测距或指纹匹配, 但几何测距建立在理想化视距传播假设之上, 非视距与多径叠加导致测距误差急剧增大; 指纹匹配中位置与特征的映射关系不稳定, 易受多径干扰, 出现测距失真、指纹区分度下降, 复杂场景下定位准确度偏低。近年来, 基于数据驱动的机器学习和深度学习方法, 凭借其特征提取和非线性拟合能力, 取得了优于传统方法的性能, 但在大规模实际部署中仍面临两方面挑战。

其一, 强弱标签样本严重不均衡导致模型泛化性能骤降。受标签性能差异、附着材料 (金属/液体/塑料) 对反向散射信号的衰减影响, 弱标签 (单位时间内读取次数低于数据集全局平均值的标签) 的有效样本量缺乏, 在本文服装陈列场景中, 弱标签的有效样本仅为强标签的 30% 左右, 样本稀缺极易导致模型过拟合, 大幅降低全局定位效果。

其二, 多径叠加导致信号的位置相关特征区分度严重下降。多径混叠的信号会掩盖标签位置带来的固有特征差异, 相位差的空间分布被多径叠加破坏, 接收信号强度指示 (Received Signal Strength Indicator, RSSI) 与距离之间的映射关系不一定完全对应, 时延

功率谱包络的峰值位置也未必唯一对应直射径。现有深度学习方法主要依赖数据驱动的黑箱拟合, 未显式利用多径信道的时域慢变性结构, 导致在强多径环境中难以从混叠信号中分离出位置相关的固有特征, 定位鲁棒性严重不足。

针对上述问题, 本文提出一种融合物理约束数据增强与多径 Transformer 的室内定位方法 (Physically Constrained Data Augmentation and MultiPath-Aware Transformer, PCDA-MPAT), 综合数据与模型两个层面考虑, 首次将物理传播规律显式编码进数据增强过程, 并与时域多径感知结构的 Transformer 联合优化, 有别于现有仅依赖数据增强或仅改进模型结构的单一思路。主要创新工作如下:

(1) 提出物理约束的数据增强 (Physically Constrained Data Augmentation, PCDA) 方法, 解决了弱标签样本生成的物理有效性难题。针对挑战一 (样本不均衡), 以相位-频率斜率一致性作为物理约束条件, 构建带有梯度惩罚的条件 Wasserstein 生成对抗网络 (Wasserstein Generative Adversarial Network with Gradient Penalty, WGAN-GP), 以信道固有参数为输入, 生成既匹配实测分布、又遵循无线传播规律的样本, 从数据根源上缓解弱标签样本不均衡问题。

(2) 提出多径感知 Transformer (MultiPath-Aware Transformer, MPAT) 定位模型, 实现了多径时域结构的显式建模。针对挑战二 (多径特征区分度下降), 设计适配准静态多径信道慢衰落特性的时域局部窗口注意力机制, 结合时域相对位置编码, 捕捉多径特征的时域演化规律, 抑制长时域不相关的噪声干扰。MPAT 通过局部窗口注意力显式建模位置相关的多径结构, 从模型层面提升对多径特征的提取和学习能力。

1 相关工作

现有无源物联网室内定位方法主要分为 3 类: 基

于几何测量的方法、基于指纹特征的方法和基于机器学习与深度学习的方法。本节将对各类方法的研究现状进行梳理,讨论分析其存在的局限性。

1.1 基于几何测量的定位方法

基于几何测量的定位方法,其基本原理是提取反向散射信号的可测参数(如传播时间、接收信号强度、载波相位),通过信号传播模型推算出标签与读写器的距离或角度,从而通过部署环境的几何约束求解标签的空间坐标。这类方法又可以细分为三种技术路径。

一是基于时间的方法。该类方法利用信号的到达时间(Time Of Arrival, TOA)或到达时间差(Time Difference Of Arrival, TDOA)估计标签与读写器的间距^[1],而电磁波以光速传播,计时误差在纳秒级就会导致厘米级的定位偏移,因此,对硬件时钟分辨率与同步精度要求极高,严重限制了实际部署中的实用性。

二是基于RSSI的方法。该类方法将实测RSSI代入对数路径损耗模型,估计标签到读写器的间距,再通过三边测量法求解标签位置^[2]。但实际环境中,遮挡与多径反射会导致RSSI测量值剧烈波动,对数路径损耗模型无法表征复杂场景下的信号衰减特性,因此这类方法通常无法满足高精度定位应用的需求。

三是基于相位的方法。该类方法利用接收信号的到达相位差(Phase Difference Of Arrival, PDOA)估计标签与读写器的间距,经典变体包括时域PDOA(Time Domain Phase Difference Of Arrival, TD-PDOA)、空域PDOA(Spatial Domain Phase Difference Of Arrival, SD-PDOA)与频域PDOA(Frequency Domain Phase Difference Of Arrival, FD-PDOA)。其中,TD-PDOA仅适用于标签保持匀速运动的场景,无法用于静态标签定位;SD-PDOA要求标签与各天线阵元的路径差小于半个波长,当标签偏离阵列中心时,定位精度会急剧恶化^[3];FD-PDOA的测距精度与作用距离受限于载波频点间隔,且在多径丰富的环境中,相位线性变化的基础假设不再成立,导致测距误差大幅上升。

基于几何测量的方法以理想化信号传播模型为前提,但复杂多径环境中非视距(Non-Line-Of-Sight, NLOS)传播与多径叠加,导致信号不再遵循理想传播路径,定位存在极大误差,泛化能力与鲁棒性受限,难以在仓储物流、零售场景等强多径环境中落地应用。

1.2 基于指纹特征的定位方法

基于指纹特征的定位方法分为两个阶段:离线训练(勘测)阶段与在线定位(推理)阶段。离线阶段,在预设的参考点采集信号参数,构建位置-信号特征映射的指纹数据库;在线阶段,将目标标签的实测信号特征与指纹库进行匹配,通过 k 近邻(k -Nearest Neighbor, k NN)等算法估计标签位置。

LANDMARC是指纹匹配的经典方法,在环境中部署参考标签自适应捕捉信号变化特征,较几何测量方法提升了定位鲁棒性^[4]。此后相关研究主要围绕指纹库的构建与优化、特征相似性度量展开:文献[5]引入传播信道衰减系数与加权平均衰减因子,扩充了指纹特征;文献[6]基于香农信息论将指纹量化为静态分量与动态分量,提升了特征信息密度;文献[7]基于几何精度因子(Geometric Dilution Of Precision, GDOP)准则筛选出最优参考标签,实现巡检机器人的高精度相对定位。

基于指纹特征的定位方法规避了复杂的显式信道建模,但在多径丰富的环境中性能会严重下降。多径带来的时延扩展、相位失真与幅度波动,会使同一位置的射频指纹出现大幅时域波动,破坏了指纹-位置映射关系的稳定性与鲁棒性。

1.3 基于机器学习与深度学习的定位方法

得益于机器学习与深度学习在非线性建模方面的突出能力,近年来,无源物联网定位逐渐转向数据驱动范式。早期研究基于支持向量机(Support Vector Machine, SVM)、随机森林(Random Forest, RF)等机器学习模型^[8-9],学习信号特征到空间位置的映射,但这类方法高度依赖人工特征工程,对无线信号复杂多径特性提取不足。

随着深度学习技术的快速发展,深度神经网络被广泛用于从信号数据中自动提取高层特征,现有研究主要聚焦于双信号融合与抗多径机制设计。DFRP方法构建了相位似然模型,结合双天线差分RSSI实现货架级分类,完成了食品仓库中的二维定位^[10];DR-ILS方法采用不确定性加权的差分RSSI方案,结合迭代局部搜索算法选择参考标签,大幅降低了轴向定位误差,避免了模型陷入局部最优^[11];EchoNet提出了多径抑制与利用的统一框架,通过多通道线性拟合与空间分集恢复去噪后的相位与RSSI信号,在大规模物联网部署中实现了鲁棒的定位性能^[12]。

样本不均衡是导致机器学习和深度学习方法过拟合的主要原因,现有数据增强方法可分为两类:一类是基于插值与统计变换的传统方法,通过线性插值、合成少数类过采样技术(Synthetic Minority Oversampling TEchnique, SMOTE)^[13]等方式扩充样本,这类方法无法带来新增有效信息,反而会加剧模型对少数类样本的过拟合;另一类是基于生成对抗网络的深度学习方法,通过对抗学习拟合真实样本分布,实现样本生成,但多采用无约束生成模式,会导致生成样本违背无线传播规律,难以适配无源物联网定位场景的弱标签样本扩充需求。

因此,现有机器学习和深度学习方法推动了无源

物联网(基于射频识别)的室内定位技术发展,但仍存在两个方面局限。第一,现有方法未考虑弱标签样本不均衡问题。上述工作均假设各标签的样本分布相对均衡,其训练与测试数据均来自同一标签集合,实际部署中受标签灵敏度差异和附着材料(金属/液体/塑料)影响,弱标签的样本量仅为强标签的30%左右,模型存在严重的过拟合风险。第二,现有深度学习方法缺乏对多径结构时域特性的显式建模。上述方法虽具备特征自动提取能力,但其网络结构设计并未利用室内多径信道慢衰落(数十至数百毫秒内相对稳定)特性,在强反射环境中难以从混叠信号中分离出与位置相关的固有特征。

综上所述,现有基于几何测量、指纹特征及深度学习的方法,在复杂室内多径环境中均存在难以回避的局限。几何方法无法应对NLOS传播,指纹方法受限于特征时域波动,深度学习方法则未解决强弱标签

样本不均衡的问题,也缺少对多径结构的显式建模。为此,本文提出PCDA-MPAT方法,区别于上述三类方法:与几何方法相比,不依赖理想化信道模型;与指纹方法相比,无需大规模离线勘测;与现有深度学习方法相比,首次将物理传播规律(相位-频率斜率一致性)编码到数据增强中,并设计时域局部窗口注意力机制显式建模多径慢衰落结构。

2 PCDA-MPAT定位方法

针对无源物联网室内定位面临的两大挑战——强弱标签样本严重不均衡、多径传播导致的特征区分度下降,本文提出了PCDA-MPAT定位方法,包括PCDA、MPAT两部分。其中,PCDA用于解决弱标签样本稀缺与不均衡问题,MPAT用于实现多径环境下的鲁棒位置特征提取,如图1所示。以下分别阐述两个部分的设计原理与具体实现。




图1 PCDA-MPAT定位方法

Figure 1 PCDA-MPAT localization method

2.1 PCDA:物理约束的数据增强方法

多径导致的信号遮挡、标签硬件的差异性等,使得不同标签的有效观测样本量存在巨大差异。观测样本量不足的标签会成为训练中的弱样本,增加深度模型的过拟合风险,降低模型泛化能力。本文提出物理约束的数据增强方法,在为样本量不足的标签合成补充观测数据的同时,显式引入无线传播约束,缓解样本不均衡问题。原始无源物联网数据集包含标签的电子产品代码(Electronic Product Code, EPC)、设备标识符(qid)、天线标识符(antennaid)、RSSI、起始相位、终止相位、频率与时间戳。对于读取次数低于全局平均值的标签,PCDA利用不同qid-antennaid-频率配置下的实测RSSI与相位数据,生成符合传播规律的补充样本,直至标签的观测样本量达到全局平

均值。

2.1.1 相位周期正余弦编码

相位的取值范围为 $[0^\circ, 360^\circ]$,具有固有的周期性。直接采用标量形式对相位进行生成,会在 0° 和 360° 边界引入人为的不连续性,导致合成样本的物理含义失真。为解决该问题,本文采用正余弦编码方案,将一维相位值映射为二维连续表征,编码公式为

$$\begin{cases} \phi_{\sin} = \sin\left(\frac{\pi\phi}{180}\right) \\ \phi_{\cos} = \cos\left(\frac{\pi\phi}{180}\right) \end{cases} \quad (1)$$

其中, ϕ 为原始相位特征(单位:°)。原始相位可通过编码特征重构: $\phi = \arctan 2(\phi_{\sin}, \phi_{\cos})$ 。该编码方式在整个生成过程中保留了相位的物理可解释性,消除了

相位周期卷绕导致的特征边界不连续问题。

2.1.2 条件 WGAN-GP 网络架构

本文选择带有梯度惩罚的 WGAN-GP 作为数据增强的基础模型。WGAN-GP 通过 Wasserstein 距离度量真实数据与生成数据的分布差异,可有效缓解训练不稳定、模式崩溃与梯度消失问题,适用于本文中弱标签样本稀缺场景的生成任务^[14]。为避免无约束生成导致的生成样本与真实信道特性偏离,本文选取 3 个固有不变的信道参数 (qid、antennaid、频率) 作为条件输入,将其转换为独热编码同步输入生成器与判别器,确保生成样本与真实样本的信道属性一致。

生成器的输入为 32 维标准正态噪声向量与信道条件独热特征的拼接向量。利用射频信号表征的低维、稠密特性,生成器采用 4 层全连接网络实现,每个隐藏层均采用层归一化与带有泄露修正线性单元 (Leaky Rectified Linear Unit, LeakyReLU) 激活函数,以稳定训练、缓解梯度消失。网络最终输出三部分特征向量:归一化后的 RSSI、正余弦编码的起始相位、正余弦编码的终止相位,与预处理后真实样本的维度和结构完全匹配。

判别器的输入为真实/合成样本的特征表征与对应信道条件特征向量的拼接向量。判别器采用 3 层全连接网络,中间层加入丢弃率为 0.2 的随机失活 (Drop-out) 层以降低过拟合风险。网络最终输出一个标量,用于估计输入样本的 Wasserstein 距离,该输出既用于区分真实与生成数据,也作为分布对齐的训练目标。

2.1.3 带有物理约束的损失函数

在标准 WGAN-GP 损失的基础上,设计基于物理约束的相位-频率斜率一致性损失项,共同构成条件 WGAN-GP 的损失函数,不仅让生成样本贴近真实数据分布,而且遵循无线信号传播的物理规律。

(1) WGAN-GP 基础损失

WGAN-GP 通过 Wasserstein 距离度量真实数据分布与生成数据分布间的差异,引入梯度惩罚项缓解传统生成对抗网络训练的不稳定、模式崩溃和梯度消失问题,更好地适配弱标签样本稀缺条件下的小样本生成任务。判别器的损失函数定义为

$$L_D = E_{\mathbf{x} \sim P_r} [D(\mathbf{x}, \mathbf{c})] - E_{\mathbf{x} \sim P_g} [D(\mathbf{x}, \mathbf{c})] + \lambda E_{\hat{\mathbf{x}} \sim P_{\hat{\mathbf{x}}}} \left[\left(\left\| \nabla_{\hat{\mathbf{x}}} D(\hat{\mathbf{x}}, \mathbf{c}) \right\|_2 - 1 \right)^2 \right] \quad (2)$$

其中: P_r 表示真实数据分布; P_g 表示生成器生成的数据分布; $P_{\hat{\mathbf{x}}}$ 表示真实样本与生成样本均匀插值得到的分布; $\mathbf{x}$ 为样本的射频特征向量; $\mathbf{c}$ 为信道条件 (qid、antennaid、频率) 的独热编码; $\hat{\mathbf{x}}$ 为真实样本与生成样本的线性插值; λ 为梯度惩罚系数; $D(\cdot)$ 为判别器输出。生成器的基础损失以最小化真实与生成样本的

分布差异、降低判别器的区分能力为优化目标,定义为

$$L_G = -E_{\mathbf{x} \sim P_g} [D(\mathbf{x}, \mathbf{c})] \quad (3)$$

(2) 相位-频率斜率一致性损失

对于固定的标签-读写器天线组合,无源反向散射链路的接收信号为视距分量与多个非视距反射分量的复矢量叠加^[15],其复频域响应可表示为

$$r(f) = a_0(f) e^{j\phi_0(f)} + \sum_{n=1}^N a_n(f) e^{j\phi_n(f)} + z(f) \quad (4)$$

其中: $a_0(f)$ 、 $\phi_0(f)$ 为视距分量的接收幅度与相位; $a_n(f)$ 、 $\phi_n(f)$ 为第 n 条非视距分量的接收幅度与相位,接收幅度在准静态场景下与频率弱相关,可近似为恒定值; N 为多径分量数量; $z(f)$ 为与信号独立的加性高斯白噪声。在准静态室内场景中,观测周期内读写器、标签、散射体 (货架、墙体、障碍物) 均保持静止,因此各条路径的长度恒定。第 n 条非视距分量的相位为

$$\phi_n(f) = \frac{4\pi f}{c} d_n + \phi_{n,\text{ref}} + \phi_{\text{offset}} \quad (5)$$

其中: d_n 为第 n 条路径的往返传播距离; c 为电磁波在自由空间的传播速度; $\phi_{n,\text{ref}}$ 为散射体反射、标签调制引入的与频率无关的恒定附加相移; ϕ_{offset} 为系统固有相位偏移,与频率、路径均无关。在无源物联网频段 (840 MHz ~ 960 MHz) 内,观测带宽相对于载波频率较小,且路径差远小于信号波长,因此频段内各非视距分量与视距分量的相位差近似恒定^[15-16]。多径效应仅会给合成信号引入一个恒定的相位偏移,不会改变相位-频率线性关系。总接收相位可表示为

$$\phi(f) = \frac{4\pi d}{c} f + \phi_{\text{offset}} + \phi_{\text{multi}} = \frac{4\pi d}{c} f + \phi_{\text{total}} \quad (6)$$

其中, ϕ_{multi} 为多径效应带来的与频率无关的相位偏移。对频率求导可得相位-频率斜率:

$$k = \frac{d\phi(f)}{df} = \frac{4\pi d}{c} \quad (7)$$

这表明,即使在准静态强多径环境中,相位-频率斜率 k 仍与标签-天线间距 d 保持线性关系,且随 d 单调递增;多径效应仅会引入恒定相位偏移,不会改变斜率特性。将相位-频率斜率一致性损失定义为

$$L_{\text{phy}} = \left| \frac{1}{N} \sum_{i=1}^N k(\hat{\mathbf{x}}_i) - \frac{1}{M} \sum_{j=1}^M k(\mathbf{x}_j) \right| \quad (8)$$

其中: $k(\cdot)$ 为相位-频率斜率计算函数,通过最小二乘法拟合相位随频率的变化斜率得到; N 、 M 分别为生成样本与真实样本的数量。

(3) 生成器总损失函数

生成器的整体目标函数为基础损失与物理约束

损失的加权组合:

$$L_{\text{total}} = L_G + \alpha \cdot L_{\text{phy}} \quad (9)$$

其中: α 为物理约束项的权重系数,用于平衡两个优化目标,一是使生成样本的分布与实测数据匹配,二是强制生成样本遵循无线传播物理规律。本文设置 $\alpha = 0.5$,对两个目标进行等权重优化,该配置既能防止模型过拟合,又能保留真实信道样本的分布特性,是物理约束生成学习中鲁棒的基准配置。

2.1.4 样本生成的时域构建

静态室内环境中,无源物联网信号在连续数据采集周期内具有时序特性,该时序特性与多径效应高度相关,并且蕴含标签位置与周边多径传播环境的信息。因此本文构建弱标签样本时,让生成过程符合读写器数据采集规律和信道慢衰落特性,得到时序对齐的样本序列。具体流程如下:

(1)时域基线构建。针对原始弱标签数据,按 EPC、qid、antennaid 与频率进行分组,定义有效采集窗口;计算每个标签采集窗口的起止时间,所有样本的时间戳均限制在该区间内,不生成观测采集周期外的合成时间戳。

(2)时域特征生成。根据实测弱标签时间序列估计采样时间分布,合成采样间隔,再以相邻时间节点的实测样本特征作为边界条件,生成模型生成中间节点的射频特征,合成后的特征序列能够保持多径信道的时域连续性。

(3)全字段补全。对每个生成的射频特征向量,补全日期、EPC、qid、antennaid、频率等数据字段,使生成样本的字段格式和统计分布都与真实样本严格匹配。

经过 PCDA 处理后的数据集同时包含原始样本与合成样本,并保证了样本均衡、字段完整和物理合理,为后续时域多径特征提取和固定长度序列构建提供了高质量数据基础。

2.2 MPAT:多径感知 Transformer 模型

针对静态多径信道的慢时变特性,基于 Transformer 基础架构^[17],本文提出多径感知 Transformer 定位模型。模型以连续时间节点的射频特征序列为输入,通过相对位置编码时序依赖关系,采用时域局部窗口注意力机制捕捉多径信道的慢衰落动态,同时抑制全局注意力带来的长时域噪声,实现多径特征中位置相关信息的更精准提取与利用。

2.2.1 时域多径特征提取

本文提取了与空间位置强相关的多径特征向量,每个时间步对应一个特征向量,即 MPAT 模型中的单个词元。特征定义如下:

(1)相位-频率斜率。计算固定标签与天线组合

下相位与频率拟合的斜率,斜率值与标签到天线间的距离相关,是非常重要的特征^[18]。

(2)频域波动系数。计算固定标签与天线组合下不同频点的 RSSI 波动系数,可以表征多径传播带来的频率选择性衰落^[19]。

(3)天线信号均值。计算不同频率下,每个固定标签中不同天线的 RSSI 均值,可以表征标签相对于天线阵列的空间角度信息。

(4)相位周期编码特征。采用式(1)的正余弦编码方案,对起始相位与终止相位分别进行编码,可以避免周期边界的不连续问题,表征相位 $0^\circ \sim 360^\circ$ 的周期特性。

通过上述特征提取,单个时间步采集的数据转换为固定维度的特征向量,对应 MPAT 模型中该时间步的词元。

2.2.2 固定长度序列构建

MPAT 模型的输入是长度为 SEQ_LEN 的时间序列,为解决弱标签样本时域覆盖不足问题,在序列构建过程中需补充 PCDA 生成样本,具体操作如下:

(1)强标签的时域序列构建。将强标签的真实样本按采集时间排序,通过滑动窗口提取连续的 SEQ_LEN 步片段,形成固定长度的输入序列。

(2)弱标签的时域序列构建。先将弱标签的真实样本按时间戳排序,形成主干序列,再按时间顺序插入 PCDA 生成的样本,得到固定长度、按时间排序的序列,确保弱标签与强标签的输入格式保持一致。

(3)特征归一化。为稳定后续模型训练过程,采用逐特征的时域归一化方法,在降低特征幅值差异的同时保留时序关系。针对每个特征维度,在长度为 SEQ_LEN 的滑动窗口内计算均值与标准差,独立执行 Z-score 标准化,归一化后的序列被输入 Transformer 编码器。

在本文场景中,Transformer 的词元(Token)定义为序列中单个时间步对应的多径特征向量,将 Transformer 的输入序列长度固定为 SEQ_LEN,每个输入包含 SEQ_LEN 个词元,每个词元对应一个特定时间的离散数据采集事件,包含该时刻的 RSSI、相位、相位-频率斜率、波动系数等特征。下文将从输入投影层、多径感知 Transformer 编码器、定位预测层 3 部分详细阐述具体设计。

2.2.3 MPAT 模型架构

本文提出的 MPAT 模型采用仅编码器的架构,整体结构如图 2 所示,分为 3 部分:输入投影层、多径感知 Transformer 编码器、定位预测层。输入投影层完成输入特征的维度映射与时序信息编码,多径感知 Transformer 编码器通过时域局部窗口注意力机制提

取位置相关多径特征,定位预测层基于聚合后的特征完成标签位置的分类推理,实现标签位置估计。




图2 MPAT模型结构

Figure 2 MPAT model structure

(1) 输入投影层

模型接收长度为 SEQ_LEN 的时域特征序列,通过线性投影将特征映射至 $d_{model} = 64$ 维,再经层归一化与高斯误差线性单元 (Gaussian Error Linear Unit, GELU) 激活函数处理,得到输入表征。其中, d_{model} 为 Transformer 的超参数,定义了投影后每个时域词元的隐藏层维度。本文固定注意力头数,因此每个注意力头的维度为 32,处于单头维度 32~64 的典型有效区间,可兼顾模型表达能力与训练稳定性。

(2) 时域相对位置编码

由于 Transformer 具有排列不变性,原生不具备时序顺序的编码能力,因此本文通过位置编码注入时序信息。在局部窗口注意力机制中,采用时域相对位置编码,仅表征每个窗口内词元的相对位置,与局部注意力机制天然适配,可更好地捕捉短程时域依赖关系。位置编码的维度为 $d_{model} = 64$,与输入投影层的输出相加后输入编码器。

(3) 多径感知 Transformer 编码器

模型采用两层堆叠的 Transformer 编码器,每层由时域局部窗口注意力模块与前馈网络 (Feed-Forward Network, FFN) 依次组成,采用前置归一化 (Pre-Norm) 残差结构,在注意力模块与 FFN 子层前执行层归一化,可缓解梯度消失问题,有助于提升模型训练稳定性。

传统 Transformer 采用全局自注意力机制,每个词元都与序列内其他词元计算注意力,然而在多径环境

中该机制存在两个问题:一是时域距离较远的样本,其相关性通常较弱,全局注意力会引入时域干扰;二是注意力计算的复杂度随序列长度平方增长,在实时性要求高、资源受限的系统中劣势明显。

针对上述问题,本文结合准静态多径信道的慢衰落特性,设计时域滑动窗口注意力机制。对于时间步 i 的词元,注意力范围仅覆盖局部窗口 $[i-2, i+2]$,窗口随 i 沿时间轴移动,窗口外的词元被掩码屏蔽。注意力计算公式为

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_k}} + \mathbf{M}\right)\mathbf{V} \quad (10)$$

其中: $\mathbf{Q}$ 、 $\mathbf{K}$ 、 $\mathbf{V}$ 分别为注意力机制的查询、键、值矩阵,由输入词元经线性投影得到; d_k 为单个注意力头的维度; $WINDOW_SIZE$ 为窗口大小,即单个词元可进行注意力计算的相邻词元边界; $\mathbf{M}$ 为时域窗口掩码矩阵,定义为

$$\mathbf{M}_{ij} = \begin{cases} 0, & |i-j| \leq \frac{WINDOW_SIZE}{2} \\ -\infty, & \text{otherwise} \end{cases} \quad (11)$$

该掩码操作将注意力计算限制在预定义的时域邻域内的词元,降低了时域引入的噪声,同时将注意力机制的计算复杂度从 $O(L^2d)$ 降至 $O(L \cdot W \cdot d)$ (L 为序列长度, W 为窗口大小, d 为隐藏层维度)。

前馈网络采用两层全连接架构,隐藏层维度设置为 4 倍 d_{model} (即 256 维),中间层采用 GELU 激活函数,同时加入丢弃率为 0.2 的 Dropout 层以缓解过拟合。FFN 的表达式为

$$\text{FFN}(\mathbf{x}) = \text{Linear}\left(\text{Dropout}\left(\text{GELU}\left(\text{Linear}(\mathbf{x})\right)\right)\right) \quad (12)$$

(4) 定位输出层

首先,对 Transformer 编码器输出的序列内所有词元均值池化,得到全局特征表征向量,再通过两层全连接层映射至位置分类空间,最后由 Softmax 激活函数输出标签在各位置的概率分布,从而将标签定位转化为多分类问题。

3 实验结果与分析

本节对 PCDA-MPAT 方法进行丰富的实验以评估其性能:首先,介绍实验环境和数据集,确定模型自身的最优超参数组合;随后,通过消融实验量化不同模块的贡献,再通过对对比实验验证所提方法相较于主流方法的优越性;最后,对计算复杂度及 PCDA 失效边界进行分析。

3.1 实验设置

3.1.1 软硬件环境与实验设置

实验使用的硬件设备是中移百灵无源物联网设备,

每台配置4通道线极化天线,发射功率设置为30 dBm。搭建10 m×10 m的服装陈列区域作为实验场景,如图3所示。场景内放置4组金属货架,每组货架尺寸

4.5 m×0.6 m×1.3 m,均匀悬挂陈列50件衣服,货架间隔0.8 m,每个服装吊牌上贴附专属无源物联网标签,共计200个目标标签。




图3 实验场景示意图

Figure 3 Schematic diagram of experimental scene

本文方法的实现基于PyTorch 2.8.0框架,所有训练及评估在高性能服务器上完成。服务器配置为NVIDIA RTX 4080 图形处理器、Intel (R) Xeon (R) Platinum 8352V 中央处理器(主频2.10 GHz)、1.0 TB 内存。

PCDA 训练参数设置:批大小为64,学习率为 1×10^{-4} ,生成器和判别器均选用Adam 优化器。训练采用交替更新策略,生成器每更新1次,判别器相应更新3次。训练最大轮次为300个epoch,加入早停机制,若连续10个epoch内Wasserstein距离未出现新的历史最佳值,则提前终止训练。

MPAT 训练参数设置:批大小为32,学习率为 5×10^{-4} ,选用AdamW 优化器。训练最大轮次为200个epoch,加入早停机制,若连续10个epoch验证集上的损失函数值未出现新的历史最低值,则提前终止训练,防止过拟合。

3.1.2 数据集与弱标签样本补充

在服装陈列区域连续采集3小时数据,共获得1 468 961条有效样本。数据划分时以标签EPC为依据,分别取每1列70%的标签为训练集,20%的标签

为验证集,剩余10%的标签为测试集,避免了跨集信息泄露,保证了实验结果客观准确。

本文将弱标签定义为读取次数低于全标签平均次数的标签,经统计,弱标签占比达到45.5%,说明样本不均衡问题突出。通过PCDA生成弱标签补充样本,与真实弱标签样本对比RSSI、起始相位、终止相位3个特征的数据分布,结果如图4所示,可见生成样本的分布与真实样本高度吻合。此外,对3个特征的数据进行双样本柯尔莫戈洛夫-斯米尔诺夫(Kolmogorov-Smirnov, K-S)检验, p 值均大于0.05,说明真实样本与生成样本之间无统计学显著差异,PCDA生成样本符合真实信号的物理特性。

3.1.3 评估指标

由于每个标签有多条样本,为符合实际应用需求,采用标签级定位准确率作为评估指标。对每个标签所有样本的预测结果,计算不同类别的平均概率,选取概率最大的类别作为标签预测结果:

$$\hat{y}_t = \arg \max_c \left[\frac{1}{|S_t|} \sum_{i \in S_t} p_i(c) \right] \quad (13)$$

其中: S_t 为标签 t 的样本索引集合; $p_i(c)$ 为模型把第 i




图4 弱标签真实样本与生成样本分布对比

Figure 4 Distribution comparison between weak-tag real samples and generated samples

个样本预测为位置 c 的概率,基于此计算标签级准确率 A 为

$$A = \frac{1}{|T|} \sum_{i \in T} 1(\hat{y}_i = y_i^*) \times 100\%$$

(14)

其中, T 为测试标签集合, $|T|$ 为测试标签数量, y_i^* 为标签 i 的真实位置。

3.2 模型参数分析

3.2.1 时域参数

保持其余超参数固定,分别对多径感知 Transformer 模型的序列长度 SEQ_LEN 和窗口大小 WINDOW_SIZE 进行单变量校准实验,以确定最优超参数配置,结果如表 1 所示。

表 1 参数校准实验结果

Table 1 Parameter calibration experiment results

SEQ_LEN	WINDOW_SIZE	标签级准确率/%
10	3	75.71
10	5	77.14
10	7	80.00
15	3	80.71
15	5	83.57
15	7	79.29
20	3	77.86
20	5	73.57
20	7	71.43

实验结果表明,SEQ_LEN = 15、WINDOW_SIZE = 15 的配置实现了最优性能。序列长度过短无法捕捉多径信道的慢衰落特性,过长则会引入冗余时域分量,形成噪声干扰;同理,窗口过大会引入虚假的长程依赖关系,窗口过小则会丢失多径特征中的关键时域关联信息。后续实验均采用该最优配置。

3.2.2 Transformer 结构参数

固定其他超参数不变,对 Transformer 编码器层数与注意力头数进行实验,结果如表 2 所示。

表 2 Transformer 结构参数校准实验结果

Table 2 Experimental results of parameter calibration for transformer architecture

编码器层数	注意力头数	标签级准确率/%
1	2	76.43
2	2	83.57
2	4	79.26
3	2	72.86
3	4	70.71

两层编码器、两个注意力头的配置实现了最高的标签级准确率,增加编码器深度或注意力头数反而会导致性能下降,其主要原因是模型过拟合。因此,后

续实验均采用该最优配置。

3.3 消融实验

为量化 PCDA-MPAT 中各模块的独立贡献,固定环境、数据集与训练设置不变,开展消融实验,基线模型为原始数据下的全局注意力 Transformer,实验结果如表 3 所示。

表 3 消融实验结果

Table 3 Ablation experiment results

实验配置	标签级准确率/%	相对基线提升/百分点
基线	77.14	0
基线+PCDA	81.43	4.29
基线+PCDA+MPAT	83.57	6.43

基线模型的标签级准确率仅为 77.14%,与两个因素有关:一是数据集存在严重的强弱标签样本不均衡问题,容易导致模型过拟合;二是全局注意力机制引入了不可靠的长程时域依赖,对准静态多径信道的慢衰落特性效果不佳。

基线模型加入 PCDA 后,标签级准确率提升至 81.43%,绝对提升幅度达 4.29 个百分点,表明 PCDA 有效缓解弱标签样本稀缺问题,降低模型过拟合风险,从数据层面带来改善。

进一步将全局注意力 Transformer 替换为 MPAT 后,标签级准确率提升至 83.57%,较基线的绝对提升幅度为 6.43 个百分点,表明 MPAT 可有效抑制无关的长程时域干扰,适配多径信道慢衰落特性,增强多径环境下的特征提取能力。

3.4 对比实验

为检验所提方法的性能优势,选取多种主流定位方法作为基线,在相同数据集与实验环境下进行对比实验。基线方法分为 4 类,分别是传统几何测量方法、传统指纹匹配方法、传统机器学习方法和深度学习方法,对比实验的结果如表 4 所示。

表 4 不同方法的定位准确率对比

Table 4 Localization accuracy comparison of different methods

方法类别	方法名称	标签级准确率/%
传统几何测量方法	RSSI 三边测量法	41.43
传统指纹匹配方法	LANDMARC	46.43
传统机器学习方法	随机森林	60.71
深度学习方法	DR-ILS	77.86
深度学习方法	EchoNet	72.14
所提方法	PCDA-MPAT	83.57

传统几何方法(RSSI 三边测量法)与指纹方法(LANDMARC)性能最差,标签级准确率均低于 50%。RSSI 三边测量法基于视距传播假设,然而服装陈列场景中存在密集金属货架,强多径效应严重恶化了测

距精度。LANDMARC 在多径环境下鲁棒性差,同时受强弱标签样本不均衡问题的影响,难以通过指纹匹配实现准确定位。

传统机器学习方法(随机森林)的准确率为 60.71%,优于前两个传统方法,但高度依赖人工特征工程,仅能捕捉浅层特征,无法学习复杂环境中深层多径特征,并且无法有效应对弱标签样本稀缺导致的过拟合问题,在标签读取质量不均的场景下泛化性能差。

DR-ILS 方法的准确率为 77.86%,优于传统方法和机器学习方法,但对样本量极少的弱标签存在过拟合,也并未针对室内准静态多径信道的慢衰落特性设计专用结构,难以从多径混叠的信号中有效提取与位置相关的固有特征。

EchoNet 方法的准确率为 72.14%,其本质由物理模型驱动,不仅无法应对弱标签样本稀缺问题,在强多径场景中输出的“去多径”信号也可能存在误差,多径信道线性拟合不准确,导致定位误差增大。

所提 PCDA-MPAT 方法实现了 83.57% 的最优准确率,相较于 DR-ILS 提升了 5.71 个百分点,较 EchoNet 提升了 11.43 个百分点,较 RSSI 三边测量法提升超 1 倍。性能提升来源于两个协同创新:数据层面,PCDA 通过生成符合无线传播规律的物理可信弱标签样本,缓解了样本不均衡问题;模型层面,带有时域局部窗口注意力的 MPAT 模型适配了室内多径信道的慢衰落特性,过滤了长程无关时域噪声,提取了与标签位置强相关的高区分度特征。

3.5 计算复杂度与实时性分析

计算开销是无源物联网系统工业落地极为关注的指标,本节从参数量、浮点运算次数和推理时间 3 个维度,量化评估 PCDA-MPAT 的计算复杂度,并与机器学习和深度学习基线方法进行对比。PCDA-MPAT 包含离线训练与在线推理两个阶段,PCDA 仅在离线训练时生成弱标签补充样本,在线推理不涉及,因此本节仅对 MPAT 进行评估。所有实验均采用前文确定的最优超参数:序列长度为 15、局部窗口大小为 5、Transformer 编码器层数为 2、注意力头数为 2、特征维度为 64。计算开销对比结果见表 5。

表 5 不同方法的计算复杂度对比

Table 5 Computational complexity comparison of different methods

方法名称	模型参数量/ $\times 10^6$	浮点运算次数/ MFLOPs	单样本推理 时间/ms
随机森林	0.008	0.000 9	0.005
DR-ILS	0.046	0.052	0.316
PCDA-MPAT	0.113	1.036	0.063 2

从模型参数量来看,随机森林为 0.008×10^6 , DR-ILS 为 0.046×10^6 , MPAT 为 0.113×10^6 , 约为前两者的 14 倍和 2.5 倍,但仍处于轻量级范畴,远低于通用 Transformer (如 BERT-base 约 110×10^6)。因为 MPAT 专为无源物联网定位任务设计,采用仅编码器的简单架构,在充分表征多径特征的同时避免参数冗余。从浮点运算次数来看,随机森林与 DR-ILS 分别为 $0.000\ 9 \times 10^6$ 和 0.052×10^6 , MPAT 则为 1.036×10^6 , 其运算量来自多头注意力机制中的矩阵乘积累加运算。从单样本推理时间来看,随机森林为 0.005 ms, DR-ILS 为 0.316 ms, MPAT 为 0.063 ms。因为 DR-ILS 需多次调用模型进行在线迭代搜索,引入大量计算开销,而 MPAT 采用端到端前向并行计算,反而取得了比 DR-ILS 更优越的实时性。综合考虑准确率和计算复杂度,本文提出的 MPAT 表现优异。

3.6 PCDA 失效边界测试

为探究 PCDA 方法的失效边界,对强标签原始有效样本按时间戳均匀抽样,分别保留 30%、20%、10% 和 5% 的样本作为伪弱标签进行算法测试,实验设置与 3.1 节一致,结果如表 6 所示。

表 6 不同强标签样本保留比例下的定位准确率

Table 6 Localization accuracy under different retention ratios of strong tags

保留真实样本比例	仅使用真实样本 准确率/%	使用 PCDA 增强后 准确率/%
30%	79.29	81.43
20%	74.29	75.71
10%	65.71	65.71
5%	57.86	57.86

可以看出 PCDA 对定位的增益随原始样本量减少呈单调递减趋势,当强标签样本保留比例降至 10% 及以下时,PCDA 增强后的准确率与仅使用真实样本完全相同,存在明确的失效拐点。此时原始样本量已难以表达信道的多径特性,虽然 PCDA 生成样本在统计分布上与真实样本接近,但已无法为模型提供额外有效信息。本文实验数据集中,弱标签样本量处于 PCDA 的有效区间内,定位准确率 83.57% 具有可靠性。

4 讨论

4.1 所提方法优势

PCDA-MPAT 定位方法面向室内多径环境下大规模标签定位场景,与传统深度学习的纯黑盒不同:一方面,将无线传播规律嵌入数据增强与模型构建全流程,既保留了强非线性拟合能力,也通过显式物理约

束提升模型的可解释性与泛化性;另一方面,设计适配多径特性的局部窗口注意力机制,从混叠的多径信号中有效提取具备位置区分度的特征,解决传统方法在复杂环境中性能急剧恶化的问题,从而在强多径环境下实现稳定定位。

4.2 局限性与适用范围

尽管 PCDA-MPAT 在多径场景的实验中取得了不错的定位效果,但仍存在以下三方面局限:

第一,方法以准静态场景为前提,读写器、标签及主要散射体处于静止状态,若环境中出现行人等移动物体,相位-频率斜率一致性会受时变多径破坏,生成数据及提取特征不再可靠。未来可尝试引入在线自适应学习或融合多传感器信息,对信道变化进行动态补偿。

第二,方法对射频硬件的相位测量精度要求较高,实验采用的中移百灵设备可满足需求,但市面上部分商用读写器不开放相位接口,或相位存在较大测量偏差,将直接影响 PCDA 生成数据的质量。

第三,PCDA 的效果依赖弱标签原始样本量,根据 3.6 节的实验结果,弱标签应至少具有不低于全局平均读取次数 20% 的原始样本,才能保证 PCDA 对定位有增益。对于完全没有有效样本的标签,PCDA 无法生成数据,需进一步考虑跨标签协同补充策略。

5 结论

针对多径丰富环境下无源物联网定位面临的弱标签样本不均衡、多径特征区分度下降两方面问题,本文提出了 PCDA-MPAT 定位方法。首先,提出了物理约束的数据增强(PCDA)方法,通过带有相位-频率斜率一致性约束的条件 WGAN-GP 模型,合成与无线传播规律一致的训练样本,有效缓解了弱标签样本稀缺问题;其次,设计了多径感知 Transformer(MPAT)模型,通过时域局部窗口注意力机制捕捉多径信道的慢衰落时域特性,提升了多径特征的提取效果。在典型服装陈列场景的实测数据验证表明,PCDA-MPAT 的标签级定位准确率达到 83.57%,较最优方法提升了 5.71 个百分点在强多径干扰、样本不均衡场景下具有较为优异的性能,适用于智能仓储、智慧零售、工业资产管理等多种无源物联网定位场景。未来研究将聚焦模型的跨场景应用能力,构建跨场景迁移学习框架,降低模型在新场景部署时的数据采集与适配开销。

参考文献

[1] Kaune R. Accuracy studies for TDOA and TOA localization[C]//2012 15th International Conference on Informa-

tion Fusion. Piscataway: IEEE, 2012: 408-415.


- [2] Dela Cruz R, Rhodette Pedrasa J. RSSI-based localization in an emulated active RFID system[C]//2019 IEEE 10th Annual Information Technology, Electronics and Mobile Communication Conference. Piscataway: IEEE, 2019: 771-778.
- [3] Liu Junyang, Li Yuan, Zhang Yulu, et al. Passive IoT localization technology based on SD-PDOA in NLOS and multi-path environments[J]. Computers, Materials & Continua, 2024, 80(1): 913-930.
- [4] Ni L M, Liu Yunhao, Lau Y C, et al. LANDMARC: Indoor location sensing using active RFID[C]//Proceedings of the First IEEE International Conference on Pervasive Computing and Communications, 2003. Piscataway: IEEE, 2003: 407-415.
- [5] Hatem E, Abou-Chakra S, Colin E, et al. A reliable propagation channel model for a better RFID-based indoor localization system[C]//2022 4th IEEE Middle East and North Africa Communications Conference. Piscataway: IEEE, 2022: 18-23.
- [6] Nanni F M C, Marrocco G. Static and dynamic fingerprint of RFID devices[C]//2024 9th International Conference on Smart and Sustainable Technologies. Piscataway: IEEE, 2024: 1-3.
- [7] Xie Yaqin, Wang Xiaoli, Lin Peng, et al. Relative positioning of the inspection robot based on RFID tag array in complex GNSS-denied environments[J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 5503214.
- [8] Pan Zemin, Chen Cong, Yu Yishuai, et al. Research on SVM-based RFID indoor location[C]//2023 International Conference on Intelligent Sensing and Industrial Automation. New York: ACM, 2023: 1-6.
- [9] Jiang Chaoyu, Wang Boyu, Tai T O, et al. An intelligent occupancy detection system for smart tourism based on RFID passive tag antenna array and random forest[C]//2023 IEEE 13th International Conference on RFID Technology and Applications. Piscataway: IEEE, 2023: 83-86.
- [10] He Lin, Fang Zirui, He Yigang, et al. DFRP: Multipath robust dual-feature RFID positioning using phase and RSSI for food-industry warehousing[J]. IEEE Transactions on Instrumentation and Measurement, 2026, 75: 8002911.
- [11] Lv Mingfeng, Wang Zhijing, Huang Yibin. DR-ILS: High-precision RFID indoor localization via differential RSSI and iterated local search[C]//2026 International Conference on Communication Networks and Machine Learning. Piscataway: IEEE, 2026: 605-609.

- [12] Amoah B, Zhang Jian, Mao Shiwen, et al. EchoNet: Breaking through multipath barriers for high-precision RFID-IoT sensing[C]//2025 IEEE Middle East Conference on Communications and Networking. Piscataway: IEEE, 2025: 1-6.
- [13] Yong Yunfen, Tan C K, Tan I K T. SMOTE for Wi-Fi fingerprint construction in indoor positioning systems[C]//2021 IEEE International Performance, Computing, and Communications Conference. Piscataway: IEEE, 2021: 1-6.
- [14] Wu Jialing, Li Wanyi, Wu Yilin, et al. Wasserstein generative adversarial network with gradient penalty for handwritten digit generation[C]//2024 International Conference on Intelligent Robotics and Automatic Control. Piscataway: IEEE, 2024: 375-379.
- [15] Faseth T, Winkler M, Arthaber H, et al. The influence of multipath propagation on phase-based narrowband positioning principles in UHF RFID[C]//2011 IEEE-APS Topical Conference on Antennas and Propagation in Wireless Communications. Piscataway: IEEE, 2011: 1144-1147.
- [16] Tse D, Viswanath P. Fundamentals of wireless communication[M]. Cambridge: Cambridge University Press, 2005.
- [17] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[PP/OL]. V7. arXiv (2023-08-02) [2026-05-08]. <https://arxiv.org/abs/1706.03762>.
- [18] Yang Songzhen, Jin Meng, He Yuan, et al. RF-prism: Versatile RFID-based sensing through phase disentangling[C]//2021 IEEE 41st International Conference on Distributed Computing Systems. Piscataway: IEEE, 2021: 1053-1063.
- [19] Bello P. Characterization of randomly time-variant linear channels[J]. IEEE Transactions on Communications Systems, 1963, 11(4): 360-393.

作者简介



肖善鹏 男,1976年1月出生于山东省菏泽市。现为中国移动研究院物联网技术与应用研究所所长、高级工程师。主要研究方向为无源物联网、无线感知及无线通信系统等。
E-mail: xiaoshanpeng@chinamobile.com



曹艳艳 女,1983年8月出生于江苏省宿迁市。现为中国移动研究院正高级工程师。主要研究方向为物联网体系架构、无源物联网、无线通信系统等。
E-mail: caoyanyanwl@chinamobile.com



范艺晶 女,1997年1月出生于陕西省宝鸡市。现为中国移动研究院研究员。主要研究方向为无源物联网、无线感知、深度学习等。
E-mail: fanyijing@chinamobile.com



王亚敏 女,1979年11月出生于山东省菏泽市。现为中国移动研究院正高级工程师。主要研究方向为复杂系统智能优化、无源物联网、物联网等。
E-mail: wangyamin@chinamobile.com



郑师应 女,1992年10月出生于四川省宜宾市。现为中国移动研究院技术经理。主要研究方向为无源物联网、无线通信系统等。
E-mail: zhengshiying@chinamobile.com



邢飞 男,1979年2月出生于辽宁省葫芦岛市。现为清华大学教授。主要研究方向为微小卫星及微小型高精度姿态测量传感器、微米纳米测量与智能微系统技术等。中国电子学会会员编号:E190202752M。
E-mail: xingfei@mail.tsinghua.edu.cn