

DOI: 10.13382/j.jemi.B2508535

基于半监督自训练 GMM-SVM 的 NLOS 识别方法*

韦子辉^{1,2,3,4} 陈江鹏^{1,2,3,4} 王子瑞^{1,2,3,4} 赵新月^{1,2,3,4} 董 鹏^{1,2,3,4}

(1. 河北大学质量技术监督学院 保定 071002; 2. 计量仪器与系统国家地方联合工程研究中心 保定 071002; 3. 河北省能源计量与安全检测技术重点实验室 保定 071002; 4. 零碳能源建筑与计量技术教育部工程研究中心建设项目 保定 071000)

摘 要:在超宽带(UWB)无线通信系统中,非视距(NLOS)和视距(LOS)环境的准确识别对于提高定位精度和系统性能至关重要。为此提出了一种基于注意力机制结构(ATTENTION)改进稀疏自编码器(SAE)的特征提取方法,SAE通过稀疏编码学习稳定有效的特征表达,注意力机制则通过动态权重分配突出重要信息,两者结合能实现更加精准的特征降维;采用了结合高斯混合模型(GMM)和自训练支持向量机(SVM)的半监督分类策略来执行 LOS/NLOS 的状态识别,高斯混合模型用于建模提取的特征空间生成概率分布参数,随后利用自训练支持向量机来增强边缘部分分类的准确性和鲁棒性。实验结果表明,通过比较不同降维方法与 LOS/NLOS 分类器组合在 NLOS 识别任务中的性能,本研究提出的 SAE-ATTENTION 特征提取策略与 GMM-SVM 分类模型组合,在识别准确率和可靠性方面表现出显著优势。在静态实验和动态实验中,该方法的 NLOS 识别准确率分别达到 95.20% 和 93.05%,有效提升了模型在有限标记样本条件下的泛化能力。

关键词: NLOS;信道冲激响应;自编码器;注意力机制;支持向量机

中图分类号: TH70 **文献标识码:** A **国家标准学科分类代码:** 510.99

NLOS recognition based on semi-supervised self-training GMM-SVM

Wei Zihui^{1,2,3,4} Chen Jiangpeng^{1,2,3,4} Wang Zirui^{1,2,3,4} Zhao Xinyue^{1,2,3,4} Dong Peng^{1,2,3,4}

(1. School of Quality and Technical Supervision, Hebei University, Baoding 071002, China; 2. National & Local Joint Engineering Research Center of Metrology Instrument and System, Hebei University, Baoding 071002, China; 3. Hebei Key Laboratory of Energy Metering and Safety Testing Technology, Hebei University, Baoding 071002, China; 4. Engineering Research Center of Zero-carbon Energy Buildings and Measurement Techniques, Ministry of Education, Baoding 071000, China)

Abstract: In ultra-wideband wireless communication systems, the accurate identification of non-line-of-sight and line-of-sight environments is crucial for enhancing positioning accuracy and system performance. To this end, a feature extraction method based on an attention mechanism structure is proposed to enhance the sparse autoencoder. The SAE learns stable and effective feature representations through sparse coding, while the attention mechanism highlights crucial information via dynamic weight allocation. Their integration enables more precise feature dimensionality reduction. A semi-supervised classification strategy combining Gaussian Mixture Models and self-training Support Vector Machines is employed for LOS/NLOS state recognition. The GMM models the generative probability distribution parameters of the extracted feature space, while the self-training SVM enhances classification accuracy and robustness in marginal regions. Experimental results demonstrate that, when comparing the performance of different dimensionality reduction methods combined with LOS/NLOS classifiers in the NLOS recognition task, the proposed SAE-ATTENTION feature extraction strategy coupled with the GMM-SVM classification model exhibits significant advantages in recognition accuracy and reliability. In static and dynamic experiments, this approach achieved NLOS recognition accuracies of 95.20% and 93.05% respectively, effectively enhanced the model's generalisation capability under conditions of limited labelled samples.

Keywords: NLOS; channel impulse response; autoencoder; attention mechanism; support vector machine

收稿日期: 2025-07-03 Received Date: 2025-07-03

* 基金项目: 国家自然科学基金(62173122)、中央引导地方科技发展资金(246Z0402G)项目资助

0 引言

随着物联网和无线通信技术的快速发展,超宽带 (ultra-wideband, UWB) 技术因其较高的空间和时间分辨率^[1]、低功耗以及强抗干扰性^[2],使其在室内定位^[3]、室内数据传输^[4]、雷达成像^[5]等领域得到了广泛应用。然而,在室内环境中如果信号在发射机与接收机之间有墙壁、人体等障碍物导致非视距 (non-line-of-sight, NLOS) 产生的情况,超宽带系统的性能受到极大影响^[6]。这是因为信号传播路径被阻挡,信号经历反射、折射和散射,使得信号衰减和多径效应加剧,接收端接收到的信号变得更加复杂和不稳定,从而影响系统的时间分辨率和定位精度^[7]。此外,超宽带系统依赖于高带宽信号的快速传输,而 NLOS 环境中的信号质量下降可能导致误码率上升,进而影响数据传输的可靠性和速度。

近些年来,为缓解 NLOS 造成的误差主要从识别与抑制两个方向开展研究,但两者的侧重与目标不同。NLOS 识别目的是区分视距 (line-of-sight, LOS) 和 NLOS 传播路径,将识别出的 NLOS 测量数据舍弃,为后续定位做准备。主要利用概率分布函数尽可能拟合 LOS/NLOS 统计特征来检测 NLOS 路径^[8-9],或通过几何关系法,分析信号传播的几何特性和环境结构来判断信号是否处于 LOS 状态^[10-11]。随着机器学习的发展,利用从信道冲激响应 (channel impulse response, CIR) 波形提取的特征参量,有效利用信道信息结合先进的机器学习或深度学习算法判断信号的 LOS 或 NLOS 状态,这种方法在复杂环境和高维特征参量中表现出色,因此得到广泛应用^[12-13]。文献[14]采用模糊前馈神经网络,分析了总功率和第一路径功率两个 CIR 特征参数对 LOS/NLOS 分类,并进行了静态和动态实验,文献[15]提出了一种新的 1D-ConvLSTM-Attention 网络 (1D-CLANet),用于提取 UWB 的 CIR 特征和识别 NLOS 场景,提高了复杂环境中的整体识别准确性,文献[16]提出了一种基于由决策树和前馈神经网络组成的两步 NLOS 识别方法,使用新颖的信道冲激响应参数来实现室内定位。文献[17]用 CIR 提取的特征,验证了卷积神经网络、K 最近邻、逻辑回归、长短期记忆、随机梯度下降、支持向量机和集成 ML 的识别能力,并认为集成 ML 能提供更高的准确性。NLOS 抑制是指在确定信号传播过程中存在 NLOS 效应后,减弱或补偿 NLOS 传播对系统性能的影响,以提高定位或通信的精度和可靠性。文献[18]提出了 3 个新特征参量,采用基于模糊可信度的支持向量机提取特征潜在特征进行分类,并从时间和能力进行定位矫正,文献[19]利用基于滑动窗口和贝叶斯卷积方法来识别与缓解由于非视距条件引起的距离误差,同时提出了一种新的时空注意力

模块来提高所提模型的性能。文献[20]引入了一种基于遗传算法反向传播神经网络 (GA-BP) 的 UWB 测距误差识别与优化方法,对 NLOS 传播链路下测距误差和系统偏差进行校正。

综上所述,NLOS 识别是提高定位精度必不可少的步骤,现有文献在应用中通常涵盖了不同特征参数组合,却较少考虑 LOS、NLOS 类别与特征参量之间的相关性,以及特征参数之间的冗余度。通过结合特征与实时信号处理方法,可以进一步提高检测的准确性和鲁棒性,并增强模型在多种环境中识别 NLOS 信道的泛化能力。因此,本研究提出了一种 NLOS 识别模型,提取 UWB 信号脉冲冲激响应波形的特征参量—偏度、峭度、最大振幅、总能量、上升时间、平均附加时延、均方根延迟、饱和度特征,以此作为 NLOS 识别的输入特征,在稀疏自编码器 (sparse autoencoder, SAE) 中引入注意力机制 (attention mechanism, ATTENTION) 重要性权重,准确提取高维 CIR 特征参量的潜在特征,结合自训练高斯混合模型 (Gaussian mixture model, GMM) 和自训练支持向量机 (support vector machine, SVM) 算法进行 NLOS 识别。该模型能减小 CIR 特征参量中受到干扰或表达不足信息的影响,使其能够识别多种环境中的 NLOS 信道。

本研究的主要贡献包括:

- 1) 在 SAE 中引入 ATTENTION,获得相比一般自编码器更强的特征提取和抗噪声能力。同时提出了基于半监督自训练 GMM-SVM 的超宽带 NLOS 识别方法,有效解决了标注数据稀缺的问题;
- 2) 鉴于现有研究方法主要依托测距技术来提取不同传播环境中的 CIR 特征参量,在到达时间差 (TDOA) 定位环境中研究 NLOS 识别算法,创新性地提出利用主从对时信号作为现场的 LOS 标记数据;
- 3) 在静态场景及动态场景中验证了所提方法的有效性,展示了其在不同遮挡条件下的优越性能。

1 信道模型及误差来源

基于脉冲的 UWB 通信模型,信道冲激响应,如式(1)所示。

$$c(t) = \sum_{k=1}^K \alpha_k \sigma(t - \tau_k) \quad (1)$$

式中: K 为多路径组件的数量; α_k 和 τ_k 分别为第 k 分量的振幅和时延; $\sigma(t)$ 高斯无线电波形。

当发送信号在传播过程中遇到障碍物或者反射时,会产生多个到达接收器的信号,每个路径上的信号经过不同的时延和幅度衰减,最终在接收端叠加形成接收到的总信号。本研究采用了 Decawave 公司生产的 DW1000 芯片,它是支持 IEEE 802.15.4-2011 标准的低功耗射频收发器,能够记录发送和接收数据包的精确时间戳与

CIR 波形数据。如图 1 所示,为使用 DW1000 采集到的 LOS 环境和 NLOS 环境下的 CIR 波形,波形由 1 000 个冲激响应连接而成,对低峰值噪声阶段进行滤除,留下相对高峰值阶段。可以看到 LOS 场景下,CIR 波形表现为一个明显的主峰,后续的多径分量相对较小,且延迟较短 NLOS 场景下的 CIR 波形更复杂,主峰的幅度可能较低,且延迟扩展明显,多径分量的数量和幅度增加,导致信号的时域特性变得模糊;同时,NLOS 场景下,接收到的信号强度较低,噪声水平较高,第一条路径和峰值路径比在 LOS 场景下更远,接收信号的质量较差。这是由于信号室内环境中常常受到建筑物、墙壁和人体等其他结构的阻挡,信号在遇到障碍物会发生反射,形成多条传播路径,导致信号在接收器处的到达时间延迟和信号强度降低。




图 1 CIR 波形

Fig. 1 CIR waveform

NLOS 环境是导致定位误差最主要的原因之一,TDOA 定位是一种利用信号到达时间差来确定距离的方法,通过测量两基站间发射信号到目标节点的传播时间差来确定节点位置。TDOA 三基站定位模型如图 2 所示,设 3 个基站 (BS1、BS2、BS3),它们的坐标已知分别为 (x_1, y_1) 、 (x_2, y_2) 、 (x_3, y_3) ,其中 BS1 为主基站,BS2、BS3 为从基站,由主基站 (BS1) 周期性广播含高精度时间戳的同步信号,驱动从基站 (BS2、BS3) 对本地时钟进行动

态校准。为保证定时精度不受 NLOS 干扰影响,基站安装部署时需保证主从基站之间的视距通信,当目标 (MS) 在坐标 (x, y) 发出信号,3 个基站接收到信号的时间分别为 t_1 、 t_2 、 t_3 ,由此可以得到主基站与其他基站间的距离差关系是一组双曲线方程,它们的交点就是目标点的坐标。

$$\begin{cases} d_1 - d_2 = c(t_1 - t_2) = \\ \sqrt{(x - x_1)^2 - (y - y_1)^2} - \sqrt{(x - x_2)^2 - (y - y_2)^2} \\ d_1 - d_3 = c(t_1 - t_3) = \\ \sqrt{(x - x_1)^2 - (y - y_1)^2} - \sqrt{(x - x_3)^2 - (y - y_3)^2} \end{cases} \quad (2)$$

TDOA 定位通常使用匹配滤波器获取的第一峰值路径来表示信号到达时间,但由于多径效应的影响,信号到达估计时间与实际值存在较大误差,如图 2 所示。假设从基站 BS_i 处于 NLOS 环境下,产生的误差时间为 Δt_{NLOS} ,对于从基站 BS_i 和主基站 BS_1 的双曲线方程为:

$$d_i - d_1 = c(t_i + \Delta t_{NLOS} - t_j) = \sqrt{(x - x_i)^2 - (y - y_i)^2} - \sqrt{(x - x_1)^2 - (y - y_1)^2} \quad (3)$$




图 2 TDOA 定位误差模型

Fig. 2 TDOA positioning error model

在此情况下双曲线甚至可能出现多个交点,导致定位的不确定性增加。因此,通常会选择识别出 NLOS 下的基站,仅采用 LOS 条件下的基站进行位置结算。考虑

到定位基站间处于视距通路,因此主从基站间的对时通信信号可视为 LOS 信号。通过复用 TDOA 主从基站对时通信功能,一方面进行时钟同步,另一方面计算该信号的信道冲激响应特征参量作为 LOS 信道已标记样本,为后续实现半监督 NLOS 识别算法提供数据支持。

2 特征描述

对所采用的特征参量及其对分布特性进行了分析。本研究采用的特征参量如表 1 所示,主要有偏度、峭度、

最大振幅、总能量、上升时间、平均附加时延、均方根延迟、饱和度、差异指数,其表达式如表 1 所示。

通过对各特征参量的数据分布(如图 3 所示),发现以下特点。

1) LOS 环境中,CIR 的能量分布相对集中,主要集中在直接路径的到达时间附近,LOS 环境中 CIR 波形的峭度通常较高。在 NLOS 环境中信号分布在多个到达时间点,CIR 波形通常更加不对称,偏度可能更加显著,且方向可能是正偏或负偏,具体取决于各多径成分的相对强度与到达时序。

表 1 特征参量
Table 1 Characteristic parameter

特征参量名称	公式	含义
偏度	$ske = \frac{E[(c(t) - \mu_{ hl })^3]}{\sigma_{ hl }^3}$	表示信道冲激响应信号波形数据分布的方向和偏差程度
峭度	$k = \frac{E[(c(t) - \mu_{ hl })^4]}{\sigma_{ hl }^4}$	表示信道冲激响应信号波形数据分布的陡峭程度
最大振幅	$\gamma_{max} = \max\{ \gamma(t_i) \}$	表示信道冲激响应信号波形的振幅最大值
总能量	$\epsilon = \sum_{i=1}^N h(t_i) ^2$	表示信道冲激响应信号波形的能量总和
上升时间	$t_{rise} = t_{stop} - t_{start}$	表示信道冲激响应信号波形从 0.1 倍最大振幅到 0.9 倍最大振幅的时间
平均附加时延	$\tau = \frac{1}{\epsilon} \sum_{i=1}^N (t_i \gamma(t_i) ^2)$	表示信道冲激响应信号波形中多径信道时间色散的一个特性参数
均方根时延	$\tau_{rms} = \frac{1}{\epsilon} [(t_i - \tau_{med})^2 \gamma(t_i) ^2]$	表示信道冲激响应信号波形中多径信道时间色散的另一个特性参数
饱和度	$M_c = \frac{d_{max}}{d_{1max}}$	表示信道冲激响应信号第一路径附近三个幅值中最大值 d_{max} 占第一路径能量 d_{1max} 的百分比
差异指数 Idiff	$Idiff = position_{first} - position_{peak} $	表示第一个路径位置 $position_{first}$ 与累加器中的峰值路径位置 $position_{peak}$ 的差值

2) 同等距离情况下,NLOS 环境下由于障碍物遮挡,接收脉冲的能量和最大幅值通常较小。

3) LOS 环境下,第 1 个到达的路径通常也是能量最强的路径,在这种情况下,它们的索引位置很可能非常接近,甚至相同,导致差异指数 Idiff 值很小或接近 0。NLOS 环境下,多路径效应使得信号能量被分散到多个不同的时间点,导致差异指数 Idiff 值增大,饱和度降低。

4) NLOS 环境中,信号的传递通过反射、折射或散射等方式绕过障碍物,这些复杂的传播路径导致信号需要更多时间从最初上升到达到峰值信号,因此上升时间增长。

以上表明不同类别可能对特定的 CIR 特征参量具有不同的敏感性,CIR 特征参量的重要程度和表征能力在不同类别之间存在差异,不能一概而论。

3 改进算法

本研究提出了一种基于 SAE-ATTENTION 的网络模型进行 CIR 特征参量降维,结合自训练 GMM-SVM 算法有效完成 NLOS 识别。在采集到不同 CIR 特征参量后基于 SAE-ATTENTION 的特征参量降维方法能自动识别和降低那些对模型预测性能贡献较低的冗余特征的影响,从而提高模型的泛化能力和计算效率,然后通过自训练 GMM-SVM 算法模型实现精确分类。此架构,不仅能够更精确地捕捉到 CIR 波形中的关键信息,还能够在复杂的 LOS 和 NLOS 环境中实现更为准确的信号特性分类,具体流程如图 4 所示。

3.1 稀疏自编码器

自编码器是一种基于人工神经网络的无监督学习模




图 3 特征参量分布情况

Fig. 3 Distribution of characteristic parameters

型,其目的在于捕捉输入数据的隐藏特征,从而完成对原始数据的高效重构。稀疏自编码器是在自编码器的基础上增加了对隐藏层中被激活神经元的数量限制,从而通过强迫神经网络聚焦于数据中的主要特征,稀疏编码器原理如图 5 所示。

3.2 ATTENTION 结构

ATTENTION 模仿人类大脑视觉和认知系统能在众多信息中筛选出对当前任务更关键信息的能力,在信息处理的过程中为每个元素赋予特定的权重(通常在 0~1 之间)以强调关键信息的作用,从而提升模型的性能。

注意力机制是由查询向量 Q 、键向量 K 、值向量 V 和注意力权重 a 构成,它们协同工作,动态地聚焦输入中与当前任务相关的关键信息,原理如图 6 所示。

3.3 基于 ATTENTION 的稀疏自编码器

稀疏自编码器通过对激活神经元施加稀疏约束,达到降维和降低冗余性的效果,但原有结构对所有特征采取同等处理策略,缺乏对关键特征的选择性关注能力,这可能导致重要信息在编码过程中被稀释。鉴于注意力机制

可以强化关键特征,提高模型对正样本的关注度,本模型引入注意力机制来加强网络对重要特征的关注。通过注意力机制提取输入数据的重要特征,加入损失函数用于优化模型参数,确保重构数据与原始数据尽可能接近的同时控制编码层表示的稀疏性,结合自编码器进行特征降维和重构,最终得到降维后的特征数据集,其结构图如图 7 所示。具体步骤如下:

步骤 1) 数据预处理及输入

本研究提取的九类特征参量单位量纲不一致,会导致模型过度依赖数值范围较大的特征,因此在进入稀疏自编码器前先进行归一化处理。

假设原始 CIR 特征样本集合为 $X \in R^n$, 将数据映射到 $[0,1]$ 区间,将归一化后的输入向量记为 x :

$$x_i = \frac{X_i - \min(X_i)}{\max(X_i) - \min(X_i)}, i \in \{1, 2, \dots, n\} \quad (4)$$

$$x = [x_1, x_2, \dots, x_n]^T \quad (5)$$

式中: x_i 表示第 i 个特征的数据集合; X_i 表示第 i 个特征的数据集合; $\min(X_i)$ 和 $\max(X_i)$ 分别为第 i 个特征的全局最小值和最大值。




图4 算法流程

Fig. 4 Algorithmic flow




图5 稀疏自编码器结构

Fig. 5 Sparse self-encoder structure




图6 注意力机制原理

Fig. 6 Attention mechanism schematic

步骤2) ATTENTION 层注意力权重计算

输入数据 $x \in \mathbf{R}^n$, 通过线性变换将输入数据 x 转换为可学习的权重矩阵, 得到特征的初始注意力得分 s :

$$s = \mathbf{W}x + b \quad (6)$$

式中: $\mathbf{W}$ 为注意力权重矩阵; b 为偏置项。

使用 softmax 函数将初始注意力得分转换为概率分布, 并确保权重和为 1, 可得注意力分布向量 a 表达式:




图7 SAE-ATTENTION 结构

Fig. 7 SAE-ATTENTION schematic

$$a = \text{softmax}(s) = \frac{\exp(s_i)}{\sum_{j=1}^d \exp(s_j)}, i \in \{1, 2, \dots, n\} \quad (7)$$

式中: s_i 和 s_j 分别表示第 i 个特征和第 j 个特征在初始注意力得分; d 为序列长度。

输出加权后的特征集向量表示为:

$$x_{att} = a \odot x \quad (8)$$

式中: $\odot$ 表示逐元素相乘。

步骤3) 编码器降维

在编码器降维过程中, 选择 ReLU 激活函数, 其单侧抑制性可以帮助稀疏自编码器学习非线性特征, 此过程的非线性映射提取低维判别性特征表示为:

$$h = \text{ReLU}(\mathbf{W}_h x_{att} + \mathbf{b}_h) \quad (9)$$

式中: $\mathbf{W}_h$ 表示稀疏矩阵; $\mathbf{b}_h$ 表示稀疏偏置矩阵。

步骤4) 确定稀疏编码器稀疏惩罚项

选择 Kullback-Leibler (KL) 散度作为稀疏惩罚项, 通过 KL 散度衡量编码器输出的概率分布与期望稀疏分布之间的差异, 其表达式为:

$$\sum_{i=1} KL(\rho || \hat{\rho}_i) = \sum_{i=1} \rho \log \frac{\rho}{\hat{\rho}_i} + (1 - \rho) \log \frac{1 - \rho}{1 - \hat{\rho}_i} \quad (10)$$

式中: ρ 为用来约束平均激活值的稀疏性参数, 其值接近零。

步骤5) 解码器重构目标

对于解码器过程, 选择了 tanh 函数作为激活函数。其优势在于对非线性特征优良的重构能力, 以及在重构过程中提供更加平滑的网格参数, 此过程非线性映射表示为:

$$g = \tanh(\mathbf{W}_g h + \mathbf{b}_g) \quad (11)$$

式中: $\mathbf{W}_g$ 表示稀疏矩阵; $\mathbf{b}_g$ 表示稀疏偏置矩阵。

步骤6) 联合优化目标

模型通过联合优化目标函数实现参数学习, 其损失函数由重构误差项、稀疏惩罚项和正则化项 3 部分组成, 表达式如下:

$$E = \frac{1}{2n} \sum_{i=1}^n (x_i - \tilde{x}_i)^2 + \beta \sum_{i=1}^n KL(\rho | \hat{\rho}_i) + \alpha \| \mathbf{W} \|_1 \quad (12)$$

式中:第 1 项表示重构误差,选择均方误差(mean squared error, MSE)来衡量输出值与输入值的差异;第 2 项是稀疏惩罚项, x_i 为第 i 个特征输入, $\tilde{x}_i$ 是第 i 个特征的输出, β 是权重因子;第 3 项为 L1 正则化项, α 是权重因子,主要通过限制权重 $\mathbf{W}$ 值,缓解模型对训练数据的过拟合。

步骤 7) 降维结果输出

在完成联合优化后,编码器的编码层输出为 CIR 特征的低维稀疏表示,即为本研究需要得 CIR 特征降维结果 $\mathbf{x}_h$ 。

3.4 半监督自训练 GMM-SVM 分类器

GMM 是一种基于概率密度函数的聚类算法,可以被看作是多个高斯分量的加权和,这些分量最接近输入。其中每个子群体的数据分布可以用一个高斯分布(正态分布)来近似,数学表达式如下:

$$P(x) = \sum_{k=1}^K \pi_k N(x | \mu_k, \Sigma_k) \quad (13)$$

式中: x 是样本数据; K 是高斯分布数目; π_k 是第 k 个组件的混合权重; $N(x | \mu_k, \Sigma_k)$ 是高斯分布的概率密度函数,其中, μ_k 和 Σ_k 分别是第 k 个高斯分布的均值向量和协方差矩阵。

GMM 提供的类别概率是软分类,能够反映样本属于不同类别的可能性,如果两个类别的隶属度相似,即数据点在两个或多个高斯分布之间的后验概率接近,这可能导致模型对这些数据点的分类存在不确定性。

自训练 SVM 是一种用于半监督学习的经典技术,该方法在每次迭代中,使用少量有标签数据训练一个分类器模型,并使用这个模型给无标签样本分类,然后将具有高置信度的样本及其预测标签作为伪标签加入训练集,然后重新训练模型。并且在标注数据有限的情况下,自训练 SVM 可以通过利用大量未标注数据来提高模型性能,节约了标注成本,同时只需调整置信度阈值和迭代机制,不需要复杂的模型结构或训练流程。

通过对时通信信号,实时采集来获取当前环境中的 LOS 信道特征数据,这些数据携带确定性标签,为后续信道状态识别提供高置信度的监督信号的同时降低了先验成本。但传统的机器学习算法需要提供两类或多类标签才能进行模型训练,因此需要找到一个方法可以充分挖掘已标记 LOS 样本分布特征,利用 LOS 已标记样本筛选出高置信度的 LOS 与 NLOS 两类样本作为初始训练集。GMM 通过概率生成模型与 EM 算法的协同优化,可以拟合有标签 LOS 样本的损失分布,计算未标记样本属于 LOS 类别的概率。

本研究通过 GMM 的概率拟合筛选高置信度样本,结合自训练 SVM 的强分类能力迭代优化,在降低标注成本的同时提升 LOS/NLOS 分类精度,具体步骤如图 8 所示。




图 8 半监督自训练 GMM-SVM 步骤

Fig. 8 Step-by-step diagram of semi-supervised self-training GMM-SVM

第一阶段为半监督 GMM 软分类器实现概率拟合,以采集的 LOS 标记数据集为锚点,输入到 GMM 软分类器进行决策,计算出属于 LOS 信道的概率并生成初始伪标签。

步骤 1) 参数初始化

假设总共 N 个样本,其中有 N_1 个 LOS 标签样本,有 N_2 个无标签样本,计算 LOS 标签样本的初始参数均值 μ_1 和协方差矩阵 Σ_1 :

$$\mu_1 = \frac{1}{N_1} \sum_{i=1}^{N_1} x_i \quad (14)$$

$$\Sigma_1 = \frac{1}{N_1 - 1} \sum_{i=1}^{N_1} (x_i - \mu_1)(x_i - \mu_1)^T \quad (15)$$

步骤 2) 计算无标签样本属于 LOS 类别的先验概率

$$p(x_j | \text{LOS}) = \frac{1}{\sqrt{(2\pi)^d |\Sigma_1|}} \exp\left(-\frac{1}{2}(x_j - \mu_1)^T \Sigma_1^{-1}(x_j - \mu_1)\right) \quad (16)$$

步骤 3) 计算后验概率(E 步)

对于 LOS 有标签样本 x_i , 将其属于 LOS 信道的概率设置为 1, 对于其他无标签样本 x_j , 假设有 K 个高斯分布, 样本属于 LOS 信道的后验概率为:

$$\begin{cases} \gamma(y_{i=LOS} | x_i) = 1 \\ \gamma(y_{j=LOS} | x_j) = \frac{\pi_{LOS} p(x_j | \mu_{LOS}, \Sigma_{LOS})}{\sum_{k=1}^K \pi_k p(x_j | \mu_k, \Sigma_k)} \end{cases} \quad (17)$$

步骤 4) 参数优化(M 步)

基于 E 步计算得到的后验概率, 最大化期望对数似然函数以更新模型参数。参数更新会在迭代过程重复进行, 直到算法收敛。

$$\mu_k^{new} = \frac{\sum_{i=1}^{N_1} \gamma(z_{i1}) \delta_{k1} x_i + \sum_{j=1}^{N_2} \gamma(z_{j1}) \delta_{jk} x_j}{\sum_{i=1}^{N_1} \gamma(z_{i1}) \delta_{k1} + \sum_{j=1}^{N_2} \gamma(z_{j1})} \quad (18)$$

$$\Sigma_k^{new} = \frac{\sum_{i=1}^{N_1} \gamma(z_{i1}) \delta_{k1} (x_i - \mu_k^{new})(x_i - \mu_k^{new})^T + \sum_{j=1}^{N_2} \gamma(z_{jk}) \delta_{jk} (x_j - \mu_k^{new})(x_j - \mu_k^{new})^T}{\sum_{i=1}^{N_1} \gamma(z_{i1}) \delta_{k1} + \sum_{j=1}^{N_2} \gamma(z_{jk})} \quad (19)$$

$$\pi_k^{new} = \frac{\sum_{i=1}^{N_1} \gamma(z_{i1}) \delta_{k1} + \sum_{j=1}^{N_2} \gamma(z_{jk})}{N_1 + N_2} \quad (20)$$

步骤 5) 标记初始伪标签

如果计算属于 LOS 类别概率 $\geq 90\%$, 则将该样本标记为 LOS 类别; 若所属概率 $\leq 10\%$, 则将该样本标记为 NLOS 类别, 已标记类别记为 L_{train} ; 概率介于 $10\% \sim 90\%$ 之间的不进行标记, 记为 U_{train} 。

第二阶段为自训练 SVM 分类器, 选择置信度阈值 τ_i , 动态添加伪标签。

步骤 6) SVM 模型训练及概率生成

使用 L_{train} 样本训练初始 SVM 模型, 得到决策函数 $y = f(x) = \text{sgn}(\omega^T f(x) + b)$ 决策函数中非线性映射函数选择径向基核函数, 通过极大似然估计拟合 sigmoid 参数, 优化目标:

$$\min_{A, B} \sum_i [y_i \log(p_i) + (1 - y_i) \log(1 - p_i)] \quad (21)$$

选择使用 Platt 缩放将 SVM 输出映射为概率估计, 公式为:

$$p(y_j | x_j) = \frac{1}{1 + \exp(Af(x_j) + B)} \quad (22)$$

式中: $f(x_j)$ 为 SVM 对样本 x_j 的决策值; A 为缩放系数; B 为偏移系数。

步骤 7) 自训练迭代与结果输出

自训练的核心是通过迭代将模型预测的高置信度无标签样本作为伪标签加入训练集, 但这一过程的误差会随迭代逐渐积累, 形成正反馈循环, 因此高置信度样本的

选择格外重要。

本研究采用分位数法的动态置信度阈值策略, 设初值阈值 $\tau_0 = 0.95$, 衰减系数 $\delta = 0.05$, 迭代次数 t , 阈值下限为 0.6, 则动态阈值为:

$$\tau_t = \tau_0 - \delta t \quad (23)$$

使用置信度大于 τ_t 的样本更新 L_{train} 集合, 重复步骤 2) 重新训练 SVM, 更新决策函数 $f(x)$ 。

4 实验

4.1 算法复杂度分析

在训练阶段, 其复杂度主要源于两方面: 1) 注意力稀疏自编码器 (A-SAE) 为精准捕获关键特征而引入的注意力机制, 其计算复杂度为 $O(d_{in} \cdot d_h + d_{in}^2)$, 其中, d_{in} 和 d_h 分别为输入特征维度和隐藏层维度; 2) 半监督 GMM-SVM 模块采用迭代自训练策略, 其总训练复杂度为“(单次 GMM 训练复杂度 + 单次 SVM 训练复杂度 $\times$ 迭代次数)”。具体地, N_u 表示未标记样本数, K 为高斯混合分量数, T_{em} 为 EM 算法的迭代次数, $N_{train, i}$ 为第 i 次迭代的训练集规模, N_{sv} 为支持向量数。具体过程的复杂度如表 2 所示。

表 2 算法复杂度

Table 2 Algorithm complexity

阶段	步骤	复杂度
训练阶段	注意力稀疏自编码器 (A-SAE)	$O(d_{in} \cdot d_h + d_{in}^2)$ (单次迭代)
	半监督自训练 GMM-SVM	$\sum_{i=1}^I [O(N_u \cdot K \cdot d_h \cdot T_{em}) + O(N_{train, i}^2 \cdot d_h)]$
	特征提取 (A-SAE 前向传播)	$O(N_{train, i}^2 \cdot d_h)$
识别阶段	分类判决 (SVM 预测)	$O(N_{sv} \cdot d_h)$
	识别阶段总复杂度	$O(d_{in} \cdot d_h + d_{in}^2 + N_{sv} \cdot d_h)$

这种在训练阶段增加其复杂性是为性能提升而付出的合理代价。最重要的是, 在后续的在线识别阶段, 算法仅需对新样本进行一次非迭代的前向传播和分类判决, 计算量较小, 响应迅速, 能够满足 NLOS 识别任务对实时性的严格要求。因此, 本算法在保证实际应用效率的同时, 通过更精密的离线训练实现了优异的识别性能。

4.2 CIR 特征提取实验

采集墙壁、人体、玻璃和木头环境下的 LOS 与 NLOS 环境下的特征参量共 10 000 组, 采用 SAE-ATTENTION 特征降维算法训练模型后, 在注意力层计算的注意力权重结果如表 3 所示。由此可见, 模型对峭度、平均附加时延、总能量和差异指数的关注度较高, 对最大振幅、均方根实验的关注度较低, 表明峭度、平均附加时延、总能量和差异指数是识别 LOS/NLOS 的关键特征。

表 3 模型注意力权重
Table 3 Model attention weights

<i>ske</i>	<i>k</i>	<i>r_{max}</i>	<i>ε</i>	<i>t_{rise}</i>	<i>τ_{med}</i>	<i>τ_{rms}</i>	<i>Mc</i>	<i>Idiff</i>
0.111	0.055	0.017	0.193	0.0792	0.287	0.039	0.064	0.155 4

将注意力权重与样本加权后输入编码器进行目标重构,模型收敛后在编码层输出特征降维结果。为便于观察特征结果,模型在 SAE-ATTENTION 编码层将九维特征非线性降维为三维,降维后的维度代表了数据在低维潜在空间中的抽象特征表示,降维结果是模型优化的稀疏性约束和重构目标共同作用的结果,没有直接物理含义。

测试集降维结果如图 9 所示,黄色点表示 LOS 信道样本的分布情况,蓝色表示 NLOS 样本的分布情况。可以发现图 9(a)中数据点的分布较为密集,但分类边界较为明显,LOS 数据集集中在一个连续的区域,而 NLOS 则分布在一个相对独立的线性区域,这种分布表明两个类别在这 3 个特征维度上有较好的分离,这有助于分类器学习区分。将本研究提出的降维算法与传统主成分分析算法的降维结果进行对比分析,图 9(b)测试集为在 PCA 上的降维效果,可见 LOS 和 NLOS 的分布高度重叠,且特征成团状分布,两个类别之间的分离不明显,说明本研究提出算法在特征提取方面有一定改进。

4.3 NLOS 信道识别

二元混淆矩阵作为分类问题中一种常用且有效的评估工具,能够清晰地呈现分类模型的预测结果与实际类别之间的对比情况。为了系统、全面地评估所提出的半监督自训练 GMM-SVM 识别方法的有效性,采用基于二元混淆进行评价分析。常用的评价指标有准确率 (accuracy)、精确率 (precision)、召回率 (recall) 和误差率 (F1-score)。

将 LOS 信号视为正例,NLOS 信号视为负例,则评价指标如式 (24) ~ (27) 所示。

$$Accuracy = \frac{TP + TN}{TP + FP + FN + TN} \tag{24}$$


$$Precision = \frac{TP}{TP + FP} \tag{25}$$

$$Recall = \frac{TP}{TP + FN} \tag{26}$$


$$F_1\text{-score} = 2 \times \frac{Precision \times Recall}{Precision + Recall} \tag{27}$$

式中:TP 表示实际为正例,且模型正确预测为正例;FN 表示实际为正例,但被错误预测为负例;FP 表示实际为负例,但被错误预测为正例;TN 表示实际为负例,且模型正确预测为负例。

在后续模型验证中,设计了 3 组实验,实验在实验室



(a) SAR-ATTENTION降维效果
(a) SAR-ATTENTION downscaling effect



(b) PCA降维效果
(b) PCA downscaling effect

图 9 测试集降维散点图

Fig. 9 Test set downscaling scatterplot

环境与走廊环境中进行,障碍物包括墙体、人体、走廊、木板。

1) 静态实验

静态实验在实验室环境进行,如图 10 所示,主基站与从基站保持 LOS 信道,设置高度 2 m;橙色表示标签处于 NLOS 环境,绿色表示标签处于 LOS 环境。从基站分别采集每个坐标点的信道数据 250 组,总计 LOS 信道 1 000 组,NLOS 信道 1 000 组,同时采集主从基站间的 LOS 信道数据 200 组。

比较不同降维方法与分类器,使用二元混淆矩阵作为分类器识别效果的判断依据,测试结果如表 4 所示。

表 4 静态测试结果

Table 4 Static test results (%)

降维方法	分类器	Accuracy	Precision	Recall	Recall
SAE-ATTENTION	GMM-SVM	95.20	91.32	99.90	95.42
PCA	GMM-SVM	93.40	88.61	99.60	93.78
SAE-ATTENTION	GMM-KNN	92.70	87.32	99.90	93.19
SAE-ATTENTION	GMM-RF	93.15	88.02	99.90	93.58




图 10 静态实验环境

Fig. 10 Static experimental environment

从降维后特征分布情况分析,不同降维方法的识别效果如图 11 所示,图中黄色表示为 LOS 样本,蓝色表示为 NLOS 样本。图 11(a)中两种信道类别的分离度更高,而图 11(b)中两种类别的重叠区域更多,同时通过识别数据分析,采取本研究 SAE-ATTENTION 作为降维方法的识别准确度达到 95.20%,说明此方法相比于 PCA 降维效果在处理高维复杂数据及保留数据的关键信息方面更具优势。

从识别性能分析,所有方法均展现较高的 Recall 值,表明模型 LOS 样本的漏检率极低,说明 LOS 样本的引入有效强化了 LOS 类别的判别边界,同时分类器对比显示,本研究所提自训练 GMM-SVM 综合性能最优,其次为自训练 GMM-RF,而自训练 GMM-KNN 相对较弱。


2) 动态实验

动态实验环境如图 12 所示,人员手持标签在水平方向匀速移动。从基站采集与标签的信道数据 2 000 组,其中 LOS 信道 1 000 组,NLOS 信道 1 000 组,采集主从基站间的 LOS 信道数据 200 组,动态实验结果如表 5 所示。

表 5 动态测试结果


Table 5 Dynamic test results (%)					
降维方法	分类器	Accuracy	Precision	Recall	Recall
SAE-ATTENTION	GMM-SVM	93.05	88.27	99.10	93.46
PCA	GMM-SVM	89.50	83.66	93.20	88.17
SAE-ATTENTION	GMM-KNN	91.00	85.47	98.80	91.65
SAE-ATTENTION	GMM-RF	91.90	87.75	97.40	92.32

从降维后特征分布情况分析,如图 13 所示,在动态环境中的特征分布相比于静态环境更加复杂。图 13(a)中 LOS 类别呈近似线性区域分布,而 NLOS 类别分布呈现离散形态并于 LOS 类别有明显分离,图 13(b)中 PCA 降维方法在动态环境比静态环境识别准确率下降了



(a) 静态实验识别效果

(a) Static experiment recognition effect



(b) PCA降维后静态实验识别效果

(b) Static experiment recognition effects after PCA downscaling

图 11 不同降维方法静态实验效果

Fig. 11 Static experimental effects of different downscaling methods





图 12 动态实验环境


Fig. 12 Dynamic experimental environment

3.9%,这是由于 PCA 线性降维机制难以有效捕捉时变特征的非线性关联,导致关键判别信息在特征重构过程

中产生损失,这种本质缺陷使得降维后的分类特征出现显著的交融现象,直接造成后续分类器的决策边界模糊化。



(a) 动态实验识别效果
(a) Dynamic experimental recognition effect



(b) PCA后动态实验识别效果
(b) Dynamic experimental recognition effect
after PCA dimensionality reduction

图 13 不同降维方法动态实验效果

Fig. 13 Dynamic experimental effects of different
dimensionality reduction methods

从识别性能分析,动态实验中由于障碍物位置、移动速度及信号传播路径的时变性,信道特征呈现非平稳、高波动特性,显著增加了特征提取与模型识别的难度,导致NLOS识别整体性能相比静态实验有所下降。本研究所提算法虽然也有准确度下降的现象,但仍然维持在93.05%一个较好的识别水平,说明该研究算法在动态环境中具有一定鲁棒性。

3) 过渡实验

为了测试本研究所提算法在LOS和NLOS过渡环境中的性能,在实验室及走廊环境进行实验,图14中给出了运动轨迹的平面图,测试人员手持标签匀速移动,绿色表示标签与基站处于LOS信道,橙色区域由于墙壁遮挡处于NLOS信道。在两段路线中各采集LOS信道数据

500组,NLOS信道数据500组。




图 14 过渡实验环境

Fig. 14 Over-experimental environment

LOS/NLOS变化相对应的分类情况如图15所示。可以注意到,在稳定的LOS和NLOS区域误差较少,特别是LOS区域的准确度保持较高水平,但识别错误发生在过渡区域的情况会增多,这是由于信号在LOS/NLOS切换时,过渡区中多径分量较多,引发特征空间重叠。但整体而言分类准确率为91.86%,说明在稳定环境中可以保持较好的识别率,特别是在稳定的LOS区域,在LOS与NLOS的过渡环境中会有所下降,但不影响整体的分类性能,侧面说明了本研究提出算法能够有效利用少量已标记数据,在面对新数据与复杂场景时,在一定程度上展现出良好的适应性。




图 15 过渡实验效果

Fig. 15 Transitional experiment effect

5 结 论

本文基于CIR波形提取的偏度、峭度、最大振幅、总能量、上升时间、平均附加时延、均方根延迟、饱和度、差异指数9类特征参量,提出了一种有效的特征提取及NLOS识别方法。

针对超宽带信号处理中多特征参数的相关性和冗余性问题,提出了一种改进的稀疏自编码器方法,通过引入ATTENTION,优化了特征提取及降维过程,旨在减少特征间的冗余并强化特征的区分力,为了评估改进效果,将

此方法与传统的 PCA 降维算法的降维效果进行对比,证实了改进稀疏自编码器模型对 LOS/NLOS 两种类别的分离程度更高,在多特征参数分析中的优越性。针对传统监督学习方法受限于静态环境假设难以应对实际动态变化带来的特征分布偏移问题,提出了一种半监督自训练 GMM-SVM 的 NLOS 识别方法,利用 GMM 软分类的优势,同时通过自训练 SVM 利用少量已标样本实现 NLOS 识别。本研究所提算法以可控的离线训练复杂度为代价,通过深度特征提取和半监督学习有效解决了 NLOS 识别的核心挑战,并在推理应用中表现出高效率和高精度的实用价值,在静态实验与动态实验场景下均能保持较好的识别率,准确率分别达到 95.20% 和 93.05%,相较于其他传统单一算法有明显优势。

参考文献

- [1] 冯瑞瑞,毛开,朱秋明,等.超宽带频率非平稳信道硬件实时模拟研究[J].电子测量与仪器学报,2022,36(11):61-69.
FENG R R, MAO K, ZHU Q M, et al. Hardware real-time simulation of ultra-wideband frequency unsteady channel[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(11): 61-69.
- [2] 杨秀建,皇甫尚昆,敖鹏,等.基于改进全质心-Taylor 的 UWB 定位方法[J].仪器仪表学报,2024,45(10):284-294.
YANG X J, HUANGFU SH K, AO P, et al. UWB localization method based on improved full center-of-mass-Taylor [J]. Chinese Journal of Scientific Instrument, 2024, 45(10): 284-294.
- [3] YAO Y, PING S, WEI T, et al. UWB system for indoor positioning and tracking with arbitrary target orientation, optimal anchor location, and adaptive NLOS mitigation[J]. IEEE Transactions on Vehicular Technology, 2020, 69(9): 1-1.
- [4] TANG W, CULURCIELLO E. A low-power high-speed ultra-wideband pulse radio transmission system [J]. IEEE Transactions on Biomedical Circuits and Systems, 2009, 3(5): 286-92.
- [5] SHI J, SHI B, WAN L L. Longwall retreat and creep measurement based on UWB radar imaging method [J]. Mathematical Problems in Engineering, 2020, 2020(2): 1-13. DOI:10.1155/2020/4056246.
- [6] 尚德良,赵旭,李连鹏,等.基于 ICEEMDAN-CNN 的非视距识别方法[J].电子测量技术,2023,46(10):61-67.
SHANG D L, ZHAO X, LI L P, et al. Non-line-of-sight recognition method based on ICEEMDAN-CNN [J]. Electronic Measurement Technology, 2023, 46(10): 61-67.
- [7] TU C, ZHANG J, QUAN Z, et al. UWB indoor localization method based on neural network multi-classification for NLOS distance correction [J]. Sensors and Actuators: A. Physical, 2024;379115904-115904.
- [8] KHODJAEV J, PARK Y, MALIK A S. Survey of NLOS identification and error mitigation problems in UWB-based positioning algorithms for dense environments [J]. Annals of Telecommunications-Annales Des Télécommunications, 2010, 65(5-6).
- [9] WANG L, CHEN R, CHEN L, et al. A robust filter for toa based indoor localization in mixed LOS/NLOS environment [C]. International Conference on Ubiquitous Positioning Indoor Navigation and Location-Based Service, 2018.
- [10] DIAO H, ZHAO J. CMD-Based NLOS identification and mitigation in wireless sensor networks [C]. 2019 IEEE International Conference on Communications Workshops (ICC Workshops). IEEE, 2019.
- [11] ZHU Y, MA T, LI Z, et al. NLOS identification and correction based on multidimensional scaling and quasi-accurate detection [J]. IEEE Access, 2019 DOI: 10.1109/ACCESS.2019.2906866.
- [12] 韦子辉,廖戈,李明轩,等.基于 ISODATA 改进 K 均值聚类算法的 NLOS 识别技术 [J]. 电子测量技术, 2024, 47(4): 172-180.
WEI Z H, LIAO G, LI M X, et al. NLOS recognition technique based on ISODATA improved K-mean clustering algorithm [J]. Electronic Measurement Technology, 2024, 47(4): 172-180.
- [13] ZHANG J, YI Q, HUANG L, et al. Research on none-line-of-sight/line-of-sight identification method based on convolutional neural network-channel attention module [J]. Sensors, 2023, 23(20).
- [14] OLEJNICZAK A, BLASZKIEWICZ O, CWALINA K K, et al. LOS and NLOS identification in real indoor environment using deep learning approach [J]. Digital Communications and Networks, 2024, 10(5): 1305-1312.
- [15] WANG Q, CHEN M, LIU J, et al. 1D-CLANet: A novel network for NLOS classification in UWB indoor positioning system [J]. Applied Sciences, 2024, 14(17): 7609-7609.
- [16] YANG H, WANG Y, XU S, et al. Ultra-wideband ranging error mitigation with novel channel impulse response feature parameters and two-step non-line-of-sight identification [J]. Sensors, 2024, 24(5).
- [17] MUQAIBEL A H, ALAWSH S A, BINMAKHASHEN G

M. Under-Sampled UWB NLOS/LOS channel classification using machine learning [J]. Arabian Journal for Science and Engineering, 2025, 50(8): 6095-6108.

[18] New Data from China University Illuminate Findings in Support Vector Machines (UWB Sensor-based Indoor Los/NLOS Localization With Support Vector Machine Learning) [J]. Robotics & Machine Learning Daily News, 2023.

[19] SAGAR A S M S, AREFIN S, MOON E, et al. A gaussian process-enhanced non-linear function and bayesian convolution-bayesian long term short memory based ultra-wideband range error mitigation method for line of sight and non-line of sight scenarios [J]. Mathematics, 2024, 12(23): 3866.

[20] 徐恒, 刘虎, 邵慧, 等. 基于 UWB 的加权同心圆聚类室内定位方法 [J]. 电子测量与仪器学报, 2024, 38(4): 161-175.

XU H, LIU H, SHAO H, et al. UWB-based weighted concentric circle clustering indoor localization method [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(4): 161-175.

作者简介



韦子辉, 1999 年于华北理工大学获得学士学位, 2002 年于海军工程大学获得硕士学位, 2009 年于河北工业大学获得博士学位, 现为河北大学副教授、硕士生导师, 主要研究方向为检测技术、室内定位技术。

E-mail: zihui-wei@163.com

Wei Zihui received his B. Sc. degree from North China University of Science and Technology in 1999, M. Sc. degree from Naval Engineering University in 2002 and Ph. D. degree from Hebei University of Technology in 2009, respectively. Now he is an associate professor and master tutor in Hebei University. His main research interests include detection technology and indoor positioning technology.



陈江鹏, 2024 年于重庆工商大学获得学士学位, 现为河北大学硕士研究生, 主要研究方向为室内定位技术。

E-mail: jiangpeng_chen@163.com

Chen Jiangpeng received his B. Sc. degree from Chongqing Technology and Business University in 2024. Now he is a M. Sc. candidate at Hebei University. His main research interest includes indoor positioning technology.



王子瑞, 2024 年于洛阳理工学院获得学士学位, 现为河北大学硕士研究生, 主要研究方向为室内定位技术。

E-mail: 15713899296@163.com

Wang Zirui received his B. Sc. degree from Luoyang Institute of Technology in 2024. Now he is a M. Sc. candidate at Hebei University. His main research interest includes indoor positioning technology.



赵新月, 2021 年于西安邮电大学获得学士学位, 现为河北大学硕士研究生, 主要研究方向为室内定位技术。

E-mail: 2634205592@qq.com

Zhao Xinyue received her B. Sc. degree from Xi'an University of Posts and Telecommunications in 2021. Now she is a M. Sc. candidate at Hebei University. Her main research interest includes indoor positioning technology.



董鹏 (通信作者), 2012 年于石家庄机械化步兵学院获得学士学位, 现为河北大学电气工程实验师, 主要研究方向检测技术、室内定位技术。

E-mail: dongpenghbu@126.com

Dong Peng (Corresponding author) received his B. Sc. degree from Shijiazhuang Mechanized Infantry Academy in 2012. Now he is an Electrical Engineering Lab Engineer in Hebei University. His main research interests include detection technology and indoor positioning technology.