

基于 SimCLR-CIR-SC 自主分类的时间卷积神经网络室内 UWB 定位方法*

吴仕勋 王潇 蓝章礼 徐凯 张淼 靳双

(重庆交通大学信息科学与工程学院 重庆 400074)

摘要:超宽带(UWB)技术因其高时间分辨率和强穿透能力,在室内定位领域受到广泛关注。然而,传统的UWB非视距识别与补偿定位方法难以准确描述复杂环境下的信道状态,导致定位准确度和精度不足。针对信道脉冲响应(CIR)数据的特点,借鉴对比学习的SimCLR框架进行特征提取,结合谱聚类(SC)原理提出了一种基于SimCLR-CIR-SC的自主分类方法。依据自主分类结果,设计了一种基于注意力机制的时间卷积神经网络(TCN-A)模型用于确定信道状态类别。进一步针对每一类信道状态类别,设计了一种TCN-A模型用于测距误差的预测。该误差用于补偿测量距离并衡量测距的权重,结合加权最小二乘(WLS)算法实现了未知节点的定位。实验结果表明,与现有3种聚类方法相比,所提出的SimCLR-CIR-SC方法实现了对信道状态的自主有效分类和标注。TCN-A分类模型准确度达到98.16%,优于现有的5种分类模型。此外,所提定位方法在3个锚点的平均误差达到0.57 m,相较于现有4种方法定位精度最少提升了31.3%,且随着锚点数量增加定位精度显著提高。

关键词: UWB室内定位;信道状态识别;SimCLR-CIR-SC;TCN-A;WLS

中图分类号: TN966 **文献标识码:** A **国家标准学科分类代码:** 510.5015

Temporal convolutional neural network indoor UWB positioning method based on SimCLR-CIR-SC autonomous classification

Wu Shixun Wang Xiao Lan Zhangli Xu Kai Zhang Miao Jin Shuang

(School of Information Science and Engineering, Chongqing Jiaotong University, Chongqing 400074, China)

Abstract: Ultra-wide band (UWB) technology has garnered significant attention in the field of indoor positioning due to its high temporal resolution and strong penetration capability. However, traditional UWB positioning methods for non-line-of-sight (NLOS) identification and compensation often fail to accurately characterize channel states in complex environments, leading to insufficient positioning accuracy and precision. This study proposes an autonomous classification approach, termed SimCLR-CIR-SC, which leverages the SimCLR framework for feature extraction from channel impulse response (CIR) data, and combined with the principles of spectral clustering (SC). Based on the autonomous classification results, we designed a time convolutional neural network with attention mechanisms (TCN-A) model to determine channel state categories. For each identified channel state category, a customized TCN-A model is then employed to predict ranging errors. These errors are used to compensate measuring distances and calibrate ranging weights, integrating with the weighted least squares (WLS) algorithm to locate unknown nodes. Experimental results demonstrate that the proposed SimCLR-CIR-SC method effectively and autonomously classifies and labels channel states, outperforming three existing clustering methods. The TCN-A classification model achieved an accuracy of 98.16%, surpassing five existing classification models. Furthermore, the proposed positioning method achieved an average error of 0.57 meters with three anchors, enhancing the positioning accuracy by at least 31.3% compared to four existing methods, and the positioning accuracy improves substantially as the number of anchors increases.

Keywords: UWB indoor positioning; channel state identification; SimCLR-CIR-SC; TCN-A; WLS

0 引言

超宽带 (ultra-wideband, UWB) 技术因其高时间分辨率和强穿透能力而被认为是实现高精度室内定位的有力工具。UWB 信号的高时间分辨率有助于准确地分辨多径效应产生的多个回波,理论上 UWB 室内定位的精度可达到厘米级甚至毫米级^[1]。然而,在实际环境中,由于非视距 (non-line-of-sight, NLoS) 传播的影响,节点间的距离估计准确性受到严重干扰,导致基于测距的 UWB 定位精度发生严重降级^[2]。因此,如何抑制 NLoS 传播导致的测距误差,也就是抑制 NLoS 误差是一个非常值得研究的课题。

在研究 UWB 室内定位技术中,抑制 NLoS 误差的方法众多,总体可以分为两个方向^[3]。一个方向是 NLoS 识别与抛弃,对于每条传输链路先识别视距 (line-of-sight, LoS) 或 NLoS,抛弃 NLoS 条件下错误的测距信息,仅使用 LoS 条件下的良好测距信息进行位置解算。另一个方向是 NLoS 抑制与补偿,可以使用诸如卡尔曼滤波、扩展卡尔曼滤波、粒子滤波等定位方法直接抑制 NLoS 误差对位置估计的影响。另外,也可以采用纠正测距误差,用修正后的测量距离进行位置估计。为了进一步抑制 NLoS 误差的影响,可以将 NLoS 识别与 NLoS 补偿这两个策略结合在一起考虑。Feng 等^[4]首先基于信道统计信息通过支持向量机进行 NLoS 识别,然后再针对 NLoS 环境,提出了基于基站距离和角度的扩展卡尔曼滤波方法用于 NLoS 缓解。但是,采用监督学习方法检测 NLoS 时,训练集的标签标注是一个复杂且耗时的步骤。Kim 等^[5]为解决训练集标签标注问题,提出了一种基于往返时间测距误差的 UWB 信道十等分标注策略,有效降低了数据集标注的成本。

鉴于室内环境的复杂性和多变性,仅以 LoS 和 NLoS 两种情况来描述信道状态已不足以确保精确性。另外,测距误差预测方法一般采用对整个数据集进行模型训练,忽略了数据异质性,泛化能力受限,难以在复杂多变的环境中达到最佳性能^[6-7]。针对上述问题,尝试根据信道脉冲响应 (CIR) 数据的自身特性,采用无监督学习方法实现信道状态的自主分类。进一步根据每一类数据,构建多分类识别和测距误差回归模型。

1) 提出了一种基于 SimCLR-CIR-SC 的自主分类方法,无需预先指定类别数量。该方法借鉴对比学习的 SimCLR 框架并结合 CIR 数据特征构建了 SimCLR-CIR 特征提取方法,再结合谱聚类 (SC) 和特征间隙启发式算法进行无监督学习实现信道状态的自主分类。进一步采用小聚类合并算法来消除类别之间的样本不平衡问题,从而提升模型的训练效果和泛化能力。

2) 针对自主分类结果,设计了一种基于注意力机制的时间卷积神经网络 (TCN-A) 模型进行信道状态的判定。同时,对每一类信道状态设计了一种 TCN-A 模型用于测距误差的预测。该误差补偿测量距离与加权最小二乘 (WLS) 定位算法结合显著提高室内定位的精度。

3) 实验结果表明,SimCLR-CIR-SC 自主分类算法能对信道状态进行有效分类并标注,TCN-A 网络模型能够精准判定信道状态以及估计测距误差。其中,信道状态分类模型准确度达到 98.16%,测距误差的均方误差在 0.05 m 以内。

1 基于 SimCLR-CIR-SC 的 TCN 定位方案

在 UWB 系统中,由于 CIR 包含了信号传播路径的详细信息,如到达时间、幅度和相位,这些特征能够反映信道环境的物理和几何状况。借助这些信息,CIR 可以被用来对 UWB 信道进行有效的分类标注^[8]。本文依据 CIR 特征对信道状态进行自主分类,克服了传统的二分类或多分类对信道状态描述不准确,难以有效标注等不足,提出了基于 SimCLR-CIR-SC 的 TCN 定位方案,如图 1 所示。整体的定位方案分为 SimCLR-CIR-SC 自主分类、离线阶段模型训练和在线阶段位置预测 3 个部分。首先,SimCLR-CIR-SC 模型对信道状态进行自主分类并标注。其次,离线阶段对标注的数据分别进行分类和测距误差模型构建和训练。最后,在线阶段依据分类模型判断信道状态类别,并由对应类别的测距误差模型预测误差。该误差对测距进行补偿,利用 WLS 算法预测位置。

2 SimCLR-CIR-SC 自主分类

传感器能从 UWB 信号中捕获多个连续采样点的 CIR 数据,CIR 幅值图如图 2 所示,可见尽管整个 CIR 包含多路径信息,但真正有效的信息主要集中在包括第一路径在内的一段数据,其余部分大多是由于信号衰减、散射或反射引起的背景噪声和非主要路径,这些部分对于精确的定位和距离测量作用较小。

选用第 1 路径为起点的 152 个采样点 CIR 数据^[9]作为输入,每个采样点包括了 CIR 的幅值和相位信息,形成了一个维度为 152×2 的数据矩阵。这种数据组织方式确保了信息的完整性,并为后续数据处理和分析提供了丰富的信道特征。

通过对 CIR 数据进行分析并对其进行分类,本质上是一种数据挖掘技术。在数据挖掘中,聚类算法是最常用的技术之一,它可以有效地将数据集中的样本按照相似性分组。由于每条信道的 CIR 数据维度是 152×2,维度比较高且其内在结构表现出多维空间的复杂关系,而

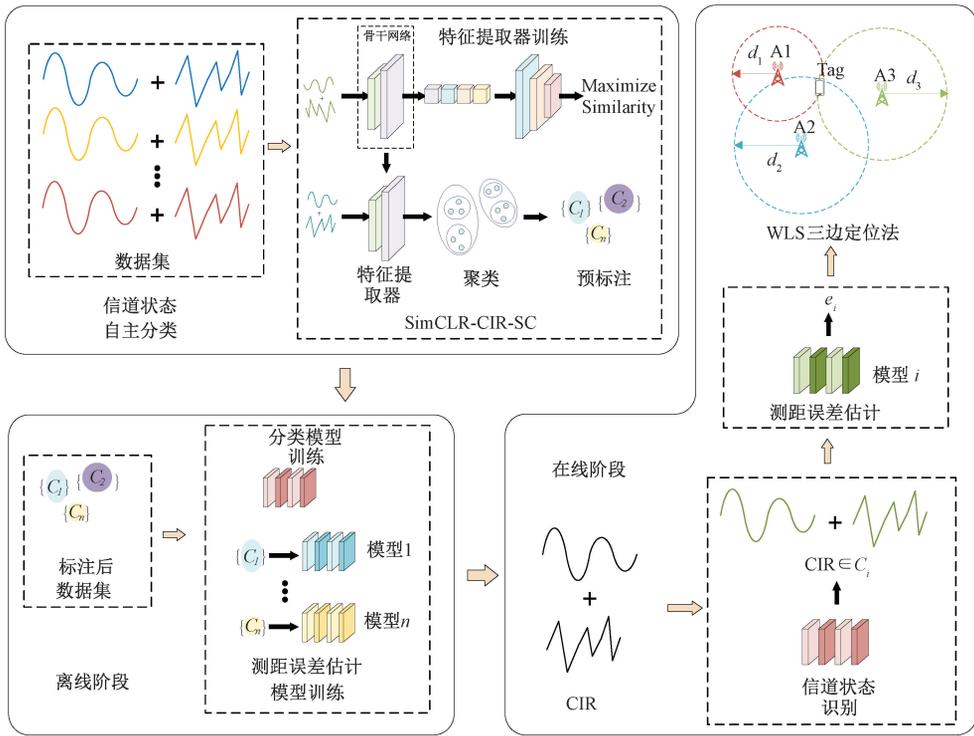


图 1 整体的定位方案

Fig. 1 UWB indoor localization solutions

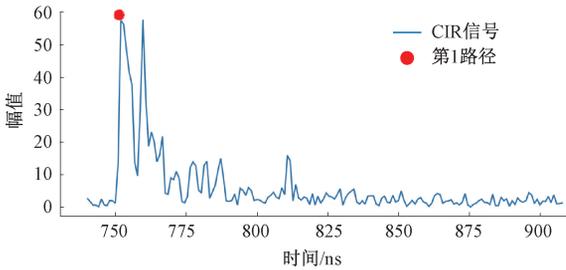


图 2 CIR 幅值图

An example of CIR

非简单的线性分布。因此,许多传统的聚类算法可能无法有效地挖掘 CIR 数据的内在结构特性,难以实现理想的聚类效果。然而,SC 算法相较于传统的聚类算法,拥有更优秀的复杂几何和非线性结构的探测能力,同时具备较强的处理高维数据的能力,并且能处理任意形状的聚类^[10]。基于此,提出了一种基于 SimCLR-CIR-SC 的自主分类方法,包括 3 个部分 SimCLR-CIR 特征提取、特征间隙启发式算法以及小聚类合并算法。

2.1 SimCLR-CIR 特征提取

SimCLR 作为一种对比学习方法^[11],能为下游任务提供高质量的特征。但该方法适合于视觉图像任务,不

能够直接用来提取具有时序特征的 CIR 数据。为此,本文提出了一种 SimCLR-CIR 特征提取方法,整体框架如图 3 所示,其关键组成部分包含数据增强、骨干网络、投影头和对比损失函数。

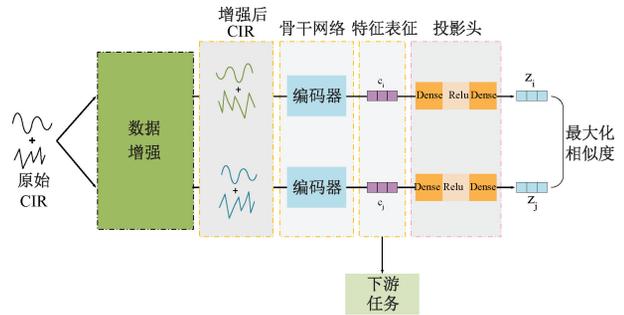


图 3 SimCLR-CIR 整体框架

Fig. 3 SimCLR-CIR framework

1) CIR 数据增强

数据增强是 SimCLR 的核心组成部分之一,文献[12]对 SimCLR 进行优化以适应时序信号的特殊性质,并且对时间序列的数据增强也进行了详细的研究。但是,数据增强策略只针对了单一维度,即幅值维度。本文 CIR 信号具有幅值和相位两个维度,幅值反映信号的

强度和衰减,而相位携带关于信号传播时间和多径效应的信息。通过对 CIR 的两个维度分别实施专门的数据增强操作,可以显著提高模型对于物理世界信号变化的适应能力。

对于幅值维度,随机左右翻转是最有效的方式^[12],在此基础上,再添加了随机噪声,并且进行随机缩放和随机平滑处理等操作实现数据增强。

假设原始信号的幅值为 m , 定义一个随机变量 γ 采样自 $\{0, 1\}$ 的均匀分布,那么随机左右翻转操作可以表示为:

$$m' = \begin{cases} m, & \gamma = 0 \\ m_{\text{rev}}, & \gamma = 1 \end{cases} \quad (1)$$

向幅值添加高斯噪声,噪声强度由因子 ϵ 控制,公式为:

$$m'' = m' + \epsilon \cdot \mathcal{N}(0, 1) \quad (2)$$

其中, $\mathcal{N}(0, 1)$ 表示均值为 0, 标准差为 1 的高斯分布, ϵ 通常设置为 0.05。

随机缩放通过一个随机因子 α 对噪声增强后的幅值进行缩放,以模拟不同环境下的信号强度变化,公式为:

$$m''' = m'' \cdot \alpha \quad (3)$$

其中, α 从区间 $[0.9, 1.1]$ 内均匀抽样。

最后,使用随机平滑既保证了数据的整体特性,又实现了数据的变化趋势。应用均值滤波器进行数据平滑处理, s 是随机确定的滤波器尺寸, s 在 $[1, 11]$ 范围内随机选取奇数值,以保持当前点的对称性,选取到 1 则表示不进行平滑,该操作可以表达为:

$$m''''[i] = \frac{1}{s} \sum_{j=i-\frac{s-1}{2}}^{i+\frac{s-1}{2}} m'''[j] \quad (4)$$

$m''''[i]$ 表示一条 CIR 幅值序列中第 i 个后的幅值,下标 j 的取值范围是从 $i - \frac{s-1}{2}$ 到 $i + \frac{s-1}{2}$, 意味着对于每个 i , 其平滑值是它及其周围 s 个点的平均值。

对于相位维度,依然选择了随机左右翻转,原理与幅值随机左右翻转相同,并且还加入了随机非线性相位变换以及随机位移。在原始相位 ϕ 的基础上添加一个正弦波形变化,其振幅和频率由随机参数控制,实现随机非线性变换,表示为:

$$\phi' = \phi + \beta \cdot \sin(2\pi ft + \theta) \quad (5)$$

其中, β 表示振幅, f 是频率, t 是时间序列, θ 是随机相位偏移。

在非线性变化后的相位上添加一个随机位移,以模拟环境噪声和设备误差的影响。

$$\phi'' = \phi' + \delta \quad (6)$$

其中, δ 是从区间 $[-0.1, 0.1]$ 内均匀抽样的位移值。

2) SimCLR-CIR 骨干网络

在 SimCLR 框架中,骨干网络负责从输入图像中提取特征表示,这些特征随后用于对比学习,通过优化对比损失函数,以最大化增强视图间的相似性,从而增强模型对数据增强形式的区分能力^[13]。由于 CIR 信号数据不同于图像数据,缺乏明显的空间维度,不同于 SimCLR 框架选择 ResNet-50 作为主干网络,SimCLR-CIR 骨干网络选择一维卷积神经网络 (1D-CNN)。研究表明,1D-CNN 在时间序列数据分析中提供卓越的性能^[12],能够有效捕捉 CIR 数据中的时间关系而非空间关系,这对于解析 CIR 信号中的特征尤为重要。这种方法确保了网络结构与数据特性的一致性,从而能够更精准地学习和提取 CIR 数据中的有用信息。

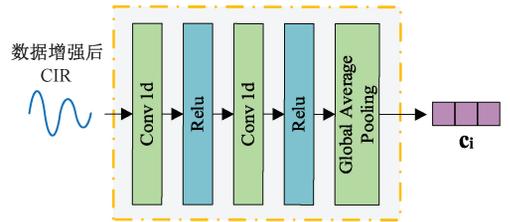


图 4 骨干网络结构

Fig. 4 Encoder framework

SimCLR-CIR 骨干网络的结构如图 4 所示,首先通过一层具有 64 个滤波器的 1D-CNN,核大小为 3,步长为 2,激活函数为 ReLU,以捕获时间序列数据的初级特征;随后应用批归一化以稳定训练过程并提升模型的泛化能力。之后,增加另一层具有 128 个滤波器的 1D-CNN,核大小为 3,步长为 1,用于进一步提取特征。最后,通过全局平均池化层来减少模型参数并缩减特征维度,为下游任务提供紧凑的特征表示。

3) SimCLR-CIR 投影头

在 SimCLR 框架中,投影头的作用是将骨干网络提取的特征投影到更低维度,这样有助于滤除那些可能对下游任务不重要的特定于任务的信息,只保留对多种任务都有用的特征^[11]。不同于 SimCLR, SimCLR-CIR 使用两个全连接层作为投影头。第 1 层的主要目的是接收来自骨干网络的特征,并进行初步的非线性变换,增加模型的表达能力。第 2 层的主要作用是进一步压缩和优化特征表示,为对比损失计算提供更精炼的特征。投影头结构如表 1 所示。

表 1 投影头参数

Table 1 Parameters of the projection head

层数	单元数	激活函数
第 1 层	64	ReLU
第 2 层	32	无

4) 对比损失函数

使用归一化温度缩放的交叉熵损失 (NT-Xent) 作为 SimCLR-CIR 的对比损失函数^[14], 其公式为:

$$L_{i,j} = -\log \frac{\exp\left(\frac{\text{sim}(z_i, z_j)}{\tau}\right)}{\sum_{k=1}^{2N} \mathbf{I}_{k \neq i} \exp\left(\frac{\text{sim}(z_i, z_k)}{\tau}\right)} \quad (7)$$

式中: $\text{sim}(z_i, z_j)$ 表示向量 z_i 和 z_j 的余弦相似度; τ 是温度参数; $\mathbf{I}_{k \neq i}$ 是一个指示函数, 当 $k \neq i$ 时为 1, 否则为 0, 确保样本不与其自身进行比较。

2.2 特征间隙启发式算法

特征间隙启发式算法是一种基于谱图理论的方法, 利用数据的拉普拉斯矩阵的特征值来估计最适合的聚类数量。首先使用最近邻方法构建稀疏相似度矩阵 S , 不仅减少了计算和存储的负担, 而且保留了数据中最重要的局部结构信息。相似度矩阵 S 的数学表达式如式 (8) 所示。

$$S = \begin{cases} 1 - d(i, j), & j \in \text{NearestNeighbors}(i) \\ 0, & \text{其他} \end{cases} \quad (8)$$

在构建稀疏相似度矩阵中, 使用余弦距离 $d(i, j)$ 来评估数据点之间的距离。对于每个点 i , 其 n 个最近邻点 j 被确定, 并在相似度矩阵 S 的相应位置填充 $1 - d(i, j)$, 确保相似度的值直接反映了数据点的近似程度, 即距离越短, 相似度越高。为了保证矩阵的对称性, 需要进行如下变换:

$$S = \frac{S + S^T}{2} \quad (9)$$

考虑到归一化问题, 通过相似度矩阵 S 计算出规范化拉普拉斯矩阵 L_{sym} 。

$$L_{\text{sym}} = I - D^{-\frac{1}{2}} S D^{-\frac{1}{2}} \quad (10)$$

式中: I 表示单位矩阵; D 是对角矩阵, 其对角线元素 D_{ii} 是矩阵 S 第 i 行之和。再计算 L_{sym} 的特征值:

$$L_{\text{sym}} \mathbf{v} = \lambda \mathbf{v} \quad (11)$$

其中, \mathbf{v} 是特征向量; λ 为特征值。

得到所有特征值后, 按照从小到大的顺序排列这些特征值, 计算相邻特征值之间的差异, 即特征间隙。

$$\Delta \lambda_i = \lambda_{i+1} - \lambda_i \quad (12)$$

最优聚类数目 k 通常选择为最大特征间隙所在的位置。

$$k = \text{argmax}_i(\Delta \lambda_i) + 1 \quad (13)$$

2.3 小聚类合并算法

为提升谱聚类的稳定性和样本均衡性, 本文使用了一种基于聚类中心距离的小聚类合并算法。该算法首先将数据点数量低于设定阈值 N_{micro} 的聚类定义为小聚类。由于数据的稀疏性或异常值的存在, 这些小聚类可能导致聚类结果不稳定。针对此问题, 本文采用如下策略进

行聚类合并。

步骤 1) 计算每个聚类的中心, 作为该聚类内所有特征向量的均值向量。数学上, 对于标记为 i 的聚类 C_i , 其中心 μ_i 定义为:

$$\mu_i = \frac{1}{|C_i|} \sum_{l \in C_i} \mathbf{l} \quad (14)$$

式中: $|C_i|$ 表示聚类 C_i 中的数据点数量; \mathbf{l} 为聚类中 C_i 的点的特征向量。

步骤 2) 构建距离矩阵。聚类中心间的距离矩阵 G 通过计算任意两个聚类中心之间的欧氏距离得到。

$$G_{i,j} = \|\mu_i - \mu_j\| \quad (15)$$

式中: μ_i 和 μ_j 表示聚类 C_i 和 C_j 的聚类中心。

步骤 3) 小聚类识别与合并。对于每个小聚类 C_k , 寻找其在距离矩阵 G 中的最近大聚类 C_n (即 $|C_n| \geq N_{\text{micro}}$), 并将 C_k 中的所有数据点重新标记为 C_n , 这一步可以表示为:

$$\text{labels}[x \in C_k] = n \quad (16)$$

这个步骤通过寻找 $G_{k,n}$ 中的最小值实现, 排除 $k = n$ 的情况, 并更新相应的聚类标签。综上所述, SimCLR-CIR-SC 方法的流程如下。

算法 1: SimCLR-CIR-SC 自主分类方法

输入: CIR 数据集 X , 近邻数 n

输出: 簇划分 C_1, C_2, \dots, C_k

- 1: 对 X 进行 SimCLR-CIR 特征提取, 得到特征集
- 2: 由式 (8) 和 (9) 构建稀疏相似度矩阵 S
- 3: 由式 (10) ~ (13) 确定最优聚类数 k
- 4: 进行谱聚类 (SC)
- 5: 由式 (10) 计算拉普拉斯矩阵 L_{sym}
- 6: 由式 (11) 对 L_{sym} 进行特征分解, 获取特征向量
- 7: 对特征向量进行 k 均值聚类, 得到聚类标签
- 8: 由式 (14) ~ (16) 进行小聚类合并算法

3 离线阶段模型训练

离线阶段, 将基于 SimCLR-CIR-SC 自主分类方法的类别进行标注, 得到 CIR 数据集来训练信道状态识别模型和测距误差预测模型。模型的输入数据为 152×2 的 CIR 数据, 其中包含了 CIR 的幅值和相位信息。

3.1 TCN-A 信道状态识别模型

本文使用 TCN 结合注意力机制构建了一种 TCN-A 网络作为信道状态识别模型。TCN 通过其独特的网络结构, 特别是扩张卷积和残差连接, 有效地捕捉了时间序列数据中的长期依赖关系, 并保证了在深层网络中信息的有效流动, 从而避免了梯度消失问题。在 TCN 的顶层结构中, 引入了注意力机制以增强模型对关键时间点特征的学习能力, 提高分类和回归性能。TCN-A 网络的结构如图 5 所示。TCN 的核心在于利用扩张卷积捕获长期依

赖信息,并通过残差连接增强学习能力和网络的深度。扩张卷积允许网络以指数级增长的感受野来处理数据,而不增加参数数量或计算复杂度。对于一维时间序列数据 z ,使用扩张卷积的输出 o 可表示为:

$$o[t] = \sum_{k=K-1}^{k=0} h[k] \cdot z[t - p \cdot k] \quad (17)$$

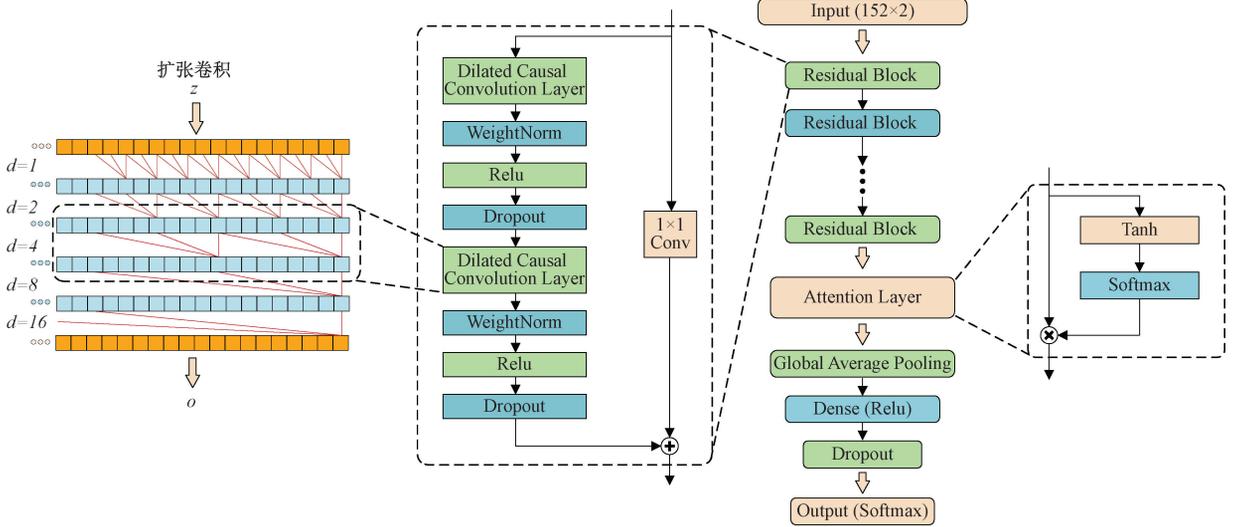


图 5 TCN-A 结构

Fig. 5 TCN-A framework

为了防止在深层网络中出现的梯度消失问题,TCN 采用了残差连接,构建残差块来代替单层扩张卷积。每个残差块的输出不仅包括通过非线性激活函数和卷积层处理后的结果,还有输入本身,这样可以形成一个信息的“快捷路径”:

$$z' = \text{Activation}(z + \text{Conv}(z)) \quad (18)$$

式中: z 是输入; Conv 是通过一系列卷积层和非线性激活函数处理后的结果。如果输入和输出的维度不匹配,可以通过一个 1×1 的卷积来调整维度。

在最后一个残差块之后引入注意力层,使得 TCN-A 网络不仅能捕捉时间序列数据中的长期依赖关系,还能通过动态和智能的方式重点处理那些对预测任务最关键的信息。注意力层是通过一个线性变换(由权重矩阵 \mathbf{W} 和偏置 b 组成)和一个非线性激活函数(\tanh)来计算每个时间步的注意力分数。然后,使用 Softmax 函数对这些分数进行归一化,得到最终的注意力权重,这些权重与输入相乘,从而得到加权的特征输出。公式如式(19)~(21)所示。

$$a = \tanh(z' \mathbf{W} + b) \quad (19)$$

$$\alpha = \text{Softmax}(a) \quad (20)$$

$$z'' = z' \otimes \alpha \quad (21)$$

注意力层之后便是全局平均池化层,用于减少时间维度,简化网络输出,为分类任务提供更精炼的特征表

式中: h 是卷积核; K 是卷积核的大小; p 是扩张率(dilation rate),它决定了输入数据中每个元素之间的间隔。随着网络深度的增加,扩张率 p 通常呈指数增长(1, 2, 4, 8, ...),这使得感受野迅速扩大。

示。然后,使用全连接层(ReLU 激活)进一步整合特征,设置中间层以提供更多的非线性处理。全连接层后再设置一层 Dropout ,进一步防止过拟合。最后在输出层通过 Softmax 函数将网络的最终输出转换为概率分布,每个类别的概率对应一个信道类型。

3.2 TCN-A 测距误差预测模型

TCN-A 网络在分类任务中表现出色,主要归功于其优秀的长期依赖关系捕获能力以及在训练阶段所展现的高效性。这种高效性源于其能够并行处理时间步的架构特性,从而大幅度提升了训练速度。此外,TCN-A 网络通过使用固定尺寸的卷积核以及巧妙地融入残差连接,进一步在内存效率和长序列处理能力方面表现出显著优势。这些特性使得 TCN-A 网络不仅适用于处理复杂的分类问题,也能有效预测连续数值,从而在多种应用场景中显示出其强大的适应能力和高度的可靠性。因此,测距误差估计模型同样使用 TCN-A 神经网络,虽整体框架保持一致,但在输出层设计上使用 Linear 函数代替 Softmax 函数,从而得到一个测距误差的预测值。同时,模型在训练阶段会根据训练的结果,在一些关键超参数上进行调整,包括扩展系数、残差块中滤波器的数量、核大小以及损失函数,以适应特定的测距需求并提高预测精度。

针对每一类信道环境,本研究分别训练独立的测距

误差预测模型。虽然这些模型共享相同的网络结构和超参数配置(包括扩张系数、每层滤波器个数、核大小、优化器和损失函数的选择),但由于训练数据集来源于 SimCLR-CIR-SC 自主分类得到的不同信道类别,其数据的内在结构和相似性特征存在显著差异。这种差异性使得模型在训练过程中学习到的权重和偏差各不相同,从而能够更好地捕捉各类信道环境下的特定模式。这种分类训练策略使得模型能够聚焦于每类信道环境中具有代表性的结构化特征,避免了对随机噪声模式的过度拟合,进而提高了测距误差预测的精度和可靠性。

4 在线阶段位置计算

在线阶段,信道状态识别模型首先根据实时获取的 UWB 信号 CIR 数据进行信道状态的判别。随后,根据分类结果选择相应的测距误差预测模型来进行测距误差的估计。测距误差将被用于补偿 WLS 定位算法,以此完成位置计算。

假设在二维平面下标签的坐标为 (x, y) , 锚点的坐标为 (x_i, y_i) , $i = 1, \dots, N$, N 表示锚点数量。考虑到测量时可能包含各种误差,标签到锚点的测量距离 r_i 为:

$$r_i = d_i + e_i = \sqrt{(x - x_i)^2 + (y - y_i)^2} + e_i \quad (22)$$

式中: e_i 为测距误差,可能由 NLoS 传播、设备精度、时钟不同步等因素引起。

使用测距误差估计模型得到的测距误差估计值 \hat{e}_i 用于测距值的补偿,得到测距估计值 \hat{d}_i , 并使其更加接近真实值,公式如式(23)所示。

$$\hat{d}_i = r_i - \hat{e}_i \quad (23)$$

使用 \hat{d}_i 替换式(22)中的 d_i 得到:

$$\hat{d}_i = \sqrt{(x - x_i)^2 + (y - y_i)^2} \quad (24)$$

引入辅助变量 $R = x^2 + y^2$, 将式(24)进行平方并整理得到:

$$\hat{d}_i^2 = R - 2x_i x - 2y_i y + x_i^2 + y_i^2 \quad (25)$$

调整式(25)的形式,将其转换为矢量形式:

$$\begin{pmatrix} -2x_i & -2y_i & 1 \end{pmatrix} \cdot \begin{pmatrix} x & y & R \end{pmatrix}^T = \hat{d}_i^2 - x_i^2 - y_i^2 \quad (26)$$

定义未知矢量 $\theta_{WLS} = [x, y, R]^T$, 并使用所有基站的信息构建线性系统 $\mathbf{H}\theta_{WLS} = \mathbf{B}$ 。其中:

$$\mathbf{H} = \begin{bmatrix} -2x_1 & -2y_1 & 1 \\ -2x_2 & -2y_2 & 1 \\ \vdots & \vdots & \vdots \\ -2x_N & -2y_N & 1 \end{bmatrix}$$

$$\mathbf{B} = \begin{bmatrix} \hat{d}_1^2 - x_1^2 - y_1^2 \\ \hat{d}_2^2 - x_2^2 - y_2^2 \\ \vdots \\ \hat{d}_N^2 - x_N^2 - y_N^2 \end{bmatrix}$$

考虑到测量的不确定性,引入权重矩阵 \mathbf{W} , 并最小化目标函数^[15]:

$$\mathbf{J} = (\mathbf{B} - \mathbf{H}\theta_{WLS})^T \mathbf{W} (\mathbf{B} - \mathbf{H}\theta_{WLS}) \quad (27)$$

最终求解标签的位置坐标如式(28)所示。

$$\hat{\theta}_{WLS} = (\mathbf{H}^T \mathbf{W} \mathbf{H})^{-1} \mathbf{H}^T \mathbf{W} \mathbf{B} \quad (28)$$

其中,

$$\mathbf{W} = \begin{bmatrix} w_1 & 0 & \cdots & 0 \\ 0 & w_2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & w_n \end{bmatrix}$$

其中, w_i 为每个测量的权重,足够精准的测距误差估计值能够精确反映当前测距值的预期精度,较小的测距误差估计值代表当前测距值的预期精度更高,反之就更低。因此,可以根据测距误差估计值 \hat{e}_i 优化权重分配,权值矩阵 \mathbf{W} 中每个权重 w_i 的计算公式为:

$$w_i = \frac{1}{\hat{e}_i^2 + \varepsilon} \quad (29)$$

式中: ε 为一个小常数,防止 w_i 为 0。测距误差更小的测距值得到更大的权重,使得权值矩阵 \mathbf{W} 更合理。

5 实验结果与分析

5.1 实验数据集

本文使用的是 2023 年发表在 Scientific Data 的公开数据集^[16]。该数据集在 4 个不同的房间进行数据采集,采用 8 基站 1 个移动标签,并且移动标签模拟人的行走路径,在等距离的位置进行采样,收集每个标签位置的多项距离测量指标以及 CIR 数据。实验从环境 0(住宅环境)和环境 2(工厂环境)的房间中抽取样本,形成 43 200 个样本点的融合数据集,其中 NLoS 信号样本数占比 51%。住宅环境通常包含各种家具和内部隔墙,这些因素会导致信号的反射、折射和散射,是研究多径效应和 NLoS 问题的理想场所。相对而言,工厂环境以其开阔的空间和丰富的金属结构为特征,这些因素通常会引起更加复杂的信号衰减和干扰模式,这两种环境使得数据集能够广泛用于分析不同环境下的定位性能以及环境因素对定位精度的影响。

5.2 自主分类实验结果与分析

1) 实验参数设置与评估指标

为验证本文提出的 SimCLR-CIR-SC 聚类方法的性能,采用经典的 K-Means^[17]、Fuzzy C-means^[18]以及原始 SC^[10]3 种方法进行对比分析。3 种聚类方法的聚类数目设置为 4,同时原始 SC 使用与 SimCLR-CIR-SC 相同的稀疏相似度矩阵构建方法,SimCLR-CIR-SC 的近邻数 n 为 50。将聚类结果通过主成分分析法降维投影到二维平面得到散点图,通过散点图可以初步直观地观察出聚类结果是否良好且有效。一个好的聚类,簇的形状应该相对简单且一致,没有非常奇怪或极度的延伸,并具有清晰的边界。考虑到样本均衡性,每个簇的大小应该相对均衡,没有一个簇显著大于或小于其他簇。

轮廓系数 (silhouette score, SS) 是衡量聚类性能的一个指标^[19],它结合了聚类的密集度和分离度两个方面。SS 的取值范围为 $[-1, 1]$,其取值越接近 1,表示样本聚类越合理;越接近 0,表示样本聚类重叠;越接近 -1,表示聚类出现错误。另外,戴维斯-布尔丁指数 (Davies-

Bouldin, DB) 是另一个衡量聚类质量的指标^[20],它基于簇内的相似性和簇间的差异性,DB 值越低表示聚类质量越高。SS 和 DB 这两个指标提供了不同的视角来评价聚类结果的质量,SS 侧重于单个点的视角,而 DB 值则侧重于簇的整体性能。

2) 实验结果与分析

4 种聚类方法散点图的实验结果如图 6 所示,图 6 (d) 为使用 SimCLR-CIR-SC 进行数据集标注的散点图,根据散点图可以直观发现聚类结果非常清晰,每个聚类的数据点聚合度较高,具有清晰的边界,且聚类间的重叠较小,形状和分布也相对均匀。图 6(a) 和 (b) 分别为 K-means 和 Fuzzy C-means 数据集标注的散点图。尽管这些图表显示出了良好的聚类效果,但某些聚类之间仍存在明显的重叠,且边界较为模糊。图 6(c) 为使用原始 SC 进行数据集标注的散点图,该方法未能对数据进行有效的聚类。大多数数据点集中于两个大聚类中,而其他较小聚类的边界与大聚类的边界相交,表明该方法难以将内在结构非常复杂的高维 CIR 数据进行有效聚类。

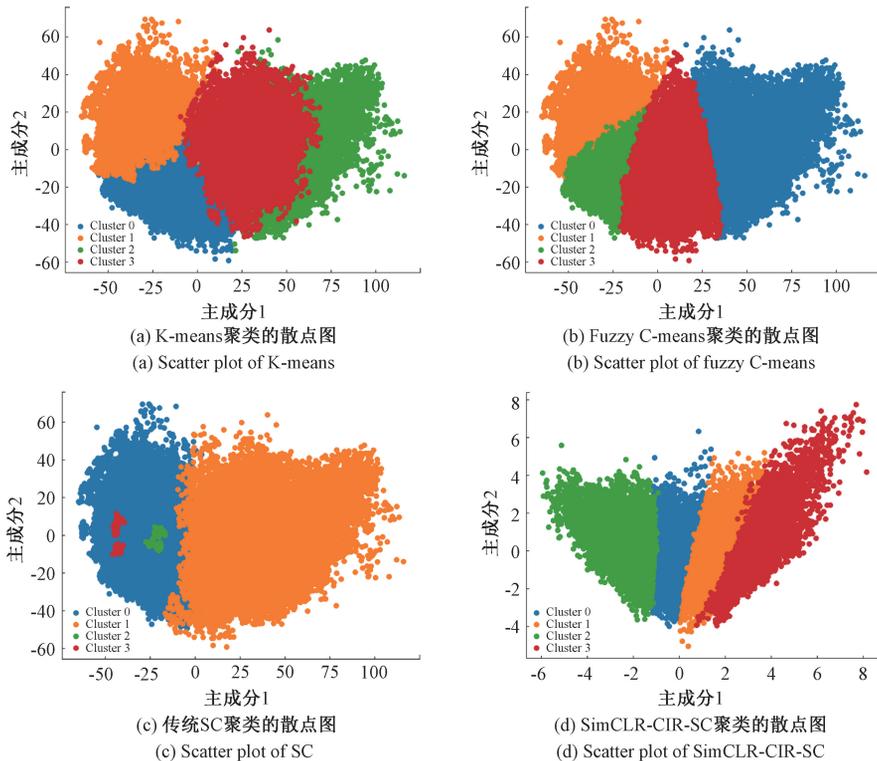


图 6 4 种聚类方法的散点图

Fig. 6 Scatter Plot of Four Clustering Methods

为了进一步对比 4 种聚类方法的性能,分类数量、各类样本数量、SS 以及 DB 值的实验结果如表 2 所示。

表 2 结果表明,SimCLR-CIR-SC 相较于 K-means、Fuzzy C-means 以及原始 SC,能够对 CIR 数据进行有效的聚类,并且样本均衡性得到了一定的保证。此外,

SimCLR-CIR-SC 的 SS 以及 DB 值两项指标也比原始 SC 更加优异。SimCLR-CIR-SC 的 SS 为 0.27,虽然不接近 1,但是正值表明大多数样本相对合理地分配到了类别中。这表明聚类具有一定程度的凝聚性和分离性,尽管提升空间仍然存在。DB 值为 1.06,相对较低,这表明聚

类的质量较好,聚类内的样本比较紧密,同时聚类之间保持了适当的距离。

表 2 4 种聚类方法性能比较

Table 2 Performance comparison of four clustering methods

方法名称	分类数量	各类样本数量	SS	DB	
K-Means ^[17]	4 类	Cluster 0	15 473	0.061	3.44
		Cluster 1	11 444		
		Cluster 2	7 042		
		Cluster 3	9 241		
		Cluster 0	12 188		
Fuzzy C-Means ^[18]	4 类	Cluster 1	10 201	0.065	4.05
		Cluster 2	9 596		
		Cluster 3	11 215		
		Cluster 0	18 114		
		Cluster 1	24 960		
原始 SC ^[10]	4 类	Cluster 2	60	0.048	2.13
		Cluster 3	66		
		Cluster 0	10 430		
		Cluster 1	11 648		
		Cluster 2	10 714		
SimCLR-CIR-SC	4 类	Cluster 3	10 408	0.270	1.06

5.3 模型训练与性能评估

1) 实验参数设置以及评估指标

CIR 数据集经过信道状态标注后,将随机选取数据集的 70% 作为训练集,其余 30% 作为测试集,训练 TCN-A 网络作为信道状态分类模型和测距误差预测模型。对于信道状态分类模型,使用准确度 (accuracy)、精确度 (precision)、召回率 (recall) 和 F1 分数 (F1 Score) 等 4 个关键指标进行性能评估和比较^[21]。信道状态分类 TCN-A 网络使用扩张系数 [1, 2, 4, 8, 16], 每层 32 个滤波器,核大小 3,采用 Adam 优化器和稀疏分类交叉熵损失函数。对于测距误差预测模型,使用均方误差 (MSE) 作为训练后的性能衡量指标^[22]。MSE 越小,表示模型预测结果与真实数据越接近,模型性能越好。误差预测 TCN-A 网络使用扩张系数 [1, 2, 4, 8, 16, 32], 每层 64 个滤波器,核大小 5,采用 Adam 优化器和 MSE 损失函数。

2) 信道状态分类模型实验结果

该部分实验为验证所提 TCN-A 模型分类的有效性,使用现有的 5 种分类模型与其进行性能比较,包括卷积神经网络 (CNN)^[23]、长短期记忆网络 (LSTM)^[24]、门控循环单元 (GRU)^[25]、双向长短期记忆网络 (BiLSTM)^[26]、TCN^[27] 对比结果如表 3 所示。

从表 3 结果来看,TCN-A 模型在所有指标上表现最优,准确度和 F1 分数均达到了 98.16% 和 98.17%,说明该模型在平衡精确度与召回率方面表现出色,能够有效识别并正确分类大部分样本。相较之下,传统的 CNN 和单向 LSTM、GRU 及 BiLSTM 模型虽然也展现了不俗的性

表 3 分类模型性能对比

Table 3 Comparison of classification model performance (%)

模型	Accuracy	Precision	Recall	F1 score
CNN ^[23]	91.64	91.71	91.71	91.69
LSTM ^[24]	95.29	95.30	95.34	95.31
GRU ^[25]	96.12	96.18	96.12	96.14
BiLSTM ^[26]	96.06	96.11	96.06	96.07
TCN ^[27]	97.22	97.29	97.21	97.24
TCN-A	98.16	98.16	98.18	98.17

能,但在处理具有复杂时间依赖性的数据时,TCN 和 TCN-A 的改进更加明显。TCN 通过其特有的扩张卷积结构提供了更深的序列理解能力,这可能是其性能优于一般 RNN 结构的原因。加入注意力机制的 TCN-A 进一步通过动态调整网络焦点来提高模型对关键信息的敏感性,这在多类标签的分类任务中尤为重要,从而实现了更高的准确度和 F1 分数。

3) 测距误差估计模型实验

本研究首先对经过预标注的数据集中的每一类别数据使用 TCN-A 网络单独进行测距误差模型的训练。然后,将这些模型的性能与未进行数据预标注、直接使用整体数据集进行训练的基于 CNN 的测距误差模型^[9]以及 TCN-A 模型进行比较分析。实验结果如表 4 所示。

表 4 测距误差估计模型性能对比

Table 4 Comparison of distance error estimation model performance

模型	MSE
CNN	0.105
TCN-A	0.094
TCN-A (Label00)	0.020
TCN-A (Label01)	0.044
TCN-A (Label02)	0.039
TCN-A (Label03)	0.018

从表 4 可以观察到,使用预标注类别训练的 TCN-A 模型在 MSE 表现上有显著差异。相比于传统的 CNN 模型和整体数据集训练的 TCN-A 模型,基于具体标注类别的 TCN-A 模型展示了更优的性能。具体而言,TCN-A 模型在未细分标注类别时的 MSE 为 0.094,而对数据进行预标注后,对应类别的 TCN-A 模型的 MSE 显著降低,特别是在标注类别“Label00”和“Label03”中,MSE 分别降至 0.02 和 0.018,显示了出色的测距精度预测能力。这说明预标注过程有助于揭示数据的内在结构,使得模型能更有效地学习和适应每种特定的信道状态。此外,对于每个标注类别单独训练的模型,其性能的提升证实了针对特定类别优化模型参数的有效性。

5.4 定位性能

该部分实验将评估不同的定位方法性能, 预设 3 个基站进行定位, 选取了数据集中环境 0 和环境 2 的 4 000 个样本进行测试, 每次定位测试执行 800 次。为了验证本研究提出的定位方法性能, 选择 4 种现有的定位方法用于对比与分析, 包括原始 WLS 定位算法、基于非视距识别的 NIDC-WLS^[28]、基于 CNN 误差补偿的 ECC-WLS^[9] 以及基于信道十分类的 MC-LSTM-WLS^[5]。定位误差是真实坐标与估计坐标的欧式距离, 统计不同定位方法分别进行 800 次实验后的平均误差、误差标准差以及误差中位数, 实验结果如图 7 所示。

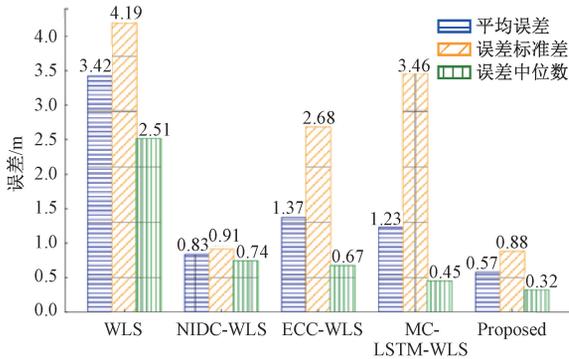


图 7 定位误差对比

Fig. 7 Comparison of positioning errors

从图 7 的 3 个误差指标上来看, 本文所提方法的定位精度是最高的, 且定位结果波动小、更加稳定。所提方法的平均误差为 0.57 m, 较 NIDC-WLS 的 0.83 m, 定位精度提升了 31.3%。ECC-WLS 和 MC-LSTM-WLS 两种方法表现稍差, 定位平均误差分别为 1.37 和 1.23 m。由于没有排除 NLoS 的影响, WLS 定位方法的精度最差, 平均误差为 3.42 m。以上实验结果验证了 NLoS 环境对 UWB 定位精度的严重影响, 并且证明了本文所提定位方法在复杂环境下的有效性和可靠性。

图 8 所示为不同方法在定位误差的累积分布函数 (CDF) 对比, 可以观察到所提出方法的性能是最好的。具体而言, 提出的方法在较小的误差范围内迅速达到较高的 CDF 值, 这表明大多数定位结果的误差较小。无任何处理的 WLS 方法表现最差, 直接进行测距误差补偿的 ECC-WLS 表现一般, 说明不进行信道分类, 单纯依赖模型进行测距误差补偿提升有限。相比之下, NIDC-WLS 和 MC-LSTM-WLS 表现略优, 表明对信道状态进行分类有助于提高定位精度, 但仍然无法与提出的方法相比。结果表明, 通过优化模型结构和信道状态标注策略, 可以显著提升定位准确性, 有效降低误差分布的宽度, 从而增强定位系统的实用性和可靠性。

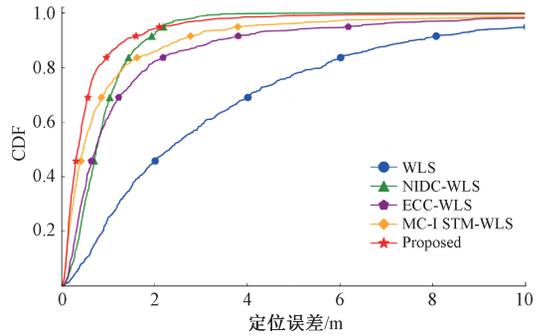


图 8 定位误差的 CDF

Fig. 8 CDF of positioning error

点数量的条件下均表现出最高的定位精度, 其平均误差从 3 个锚点的 0.578 m 稳步下降至 7 个锚点的 0.278 m, 整体性能显著优于其他对比方法。特别是与 WLS 方法相比, 所提出的方法在最少锚点配置时即展现出了更高的定位准确性, 且误差下降幅度更为平稳, 反映了该方法在信道特征提取和空间信息利用方面的显著优势。这一优异表现证实了融合先进的信道状态分类策略与网络模型, 所提出的方法极大地提升了室内定位的精确度。使用了信道状态分类策略的 NIDC-WLS、MC-LSTM-WLS 以及本研究所提方法在不同基站数量的情况下都优于其他两种方法, 这一结果突显了信道状态对 UWB 室内定位性能的重要影响。

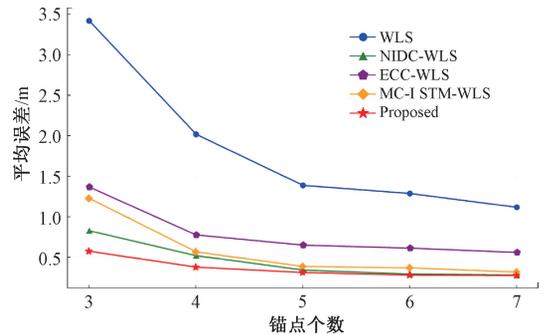


图 9 不同锚点数量的定位精度

Fig. 9 Accuracy with different numbers of anchors

6 结论

本文提出了一种基于 SimCLR-CIR-SC 的信道状态自主分类与定位系统, 成功解决了传统分类方法在复杂信道环境下的局限性以及数据标注成本。通过引入 SimCLR-CIR-SC 自主分类方法, 不仅提高了信道状态的描述精确度, 而且通过精细的数据标注, 极大地增强了定位算法的鲁棒性和准确性。该系统包括信道状态自主分类、离线模型训练和在线位置预测 3 个关键阶段, 确保了整体解决方案的高效性和实用性。在离线阶段, 系统对

由图 9 的实验结果看出, 本文提出的方法在不同锚

分类后的数据进行模型训练,构建精确的分类模型和测距误差估计模型;而在线阶段则实现了快速的信道状态判断和精准的位置计算。通过补偿测距误差,并结合加权最小二乘算法,显著提升了非视距环境下的定位准确度。实验结果验证了该方法相较于传统技术,在定位精度和适应性方面表现出显著优势。

未来工作将致力于进一步优化信道状态的自主分类方法,提升轮廓系数以实现更佳的性能,并计划采集数据以验证本研究方法的实用性和有效性。

参考文献

- [1] 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. Indoor positioning method based on UWB and weighted concentric circle clustering[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(4): 161-175.
- [2] 曹波,朱万洁,姜春霞,等. 基于 VBKF-CPA-TSA 算法的 UWB 定位技术[J]. 仪器仪表学报, 2023, 44(10): 120-129.
CAO B, ZHU W J, JIANG CH X, et al. UWB positioning technology based on the VBKF-CPA-TSA algorithm[J]. Chinese Journal of Scientific Instrument, 2023, 44(10): 120-129.
- [3] DEHMOLLAIAN E, ETZLINGER B, PETERSEIL P, et al. AI-Enhanced UWB-Based Localisation in Wireless Networks [M]. Intelligent Secure Trustable Things. Cham: Springer Nature Switzerland, 2024: 201-216.
- [4] FENG D, PENG J, ZHUANG Y, et al. An adaptive IMU/UWB fusion method for NLOS indoor positioning and navigation [J]. IEEE Internet of Things Journal, 2023, 10(13): 11414-11428.
- [5] KIM D H, FARHAD A, PYUN J Y. UWB positioning system based on LSTM classification with mitigated NLOS effects [J]. IEEE Internet of Things Journal, 2022, 10(2): 1822-1835.
- [6] YANG B, LI J, SHAO Z, et al. Self-supervised deep location and ranging error correction for UWB localization [J]. IEEE Sensors Journal, 2023, 23(9): 9549-9559.
- [7] HE X, MO L, WANG Q. An attention-assisted UWB ranging error compensation algorithm [J]. IEEE Wireless Communications Letters, 2022, 12(3): 421-425.
- [8] TRAN V, DAI Z, TRIGONI N, et al. DeepCIR: Insights into CIR-based data-driven UWB error mitigation [C]. 2022 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). IEEE, 2022: 13300-13307.
- [9] BREGAR K, MOHORČIĆ M. Improving indoor localization using convolutional neural networks on computationally restricted devices [J]. IEEE Access, 2018, 6: 17429-17441.
- [10] XIE J, KONG W, XIA S, et al. An efficient spectral clustering algorithm based on granular-ball [J]. IEEE Transactions on Knowledge and Data Engineering, 2023, 35(9): 9743-9753.
- [11] CHEN T, KORNBLITH S, NOROUZI M, et al. A simple framework for contrastive learning of visual representations [C]. International conference on machine learning. PMLR, 2020: 1597-1607.
- [12] PÖPPELBAUM J, CHADHA G S, SCHWUNG A. Contrastive learning based self-supervised time-series analysis [J]. Applied Soft Computing, 2022, 117: 108397.
- [13] YEH C H, HONG C Y, HSU Y C, et al. Decoupled contrastive learning [C]. European Conference on Computer Vision. Cham: Springer Nature Switzerland, 2022: 668-684.
- [14] LEE K H, ARNAB A, GUADARRAMA S, et al. Compressive visual representations [J]. Advances in Neural Information Processing Systems, 2021, 34: 19538-19552.
- [15] WEI J, WANG H, SU S, et al. NLOS identification using parallel deep learning model and time-frequency information in UWB-based positioning system [J]. Measurement, 2022, 195: 111191.
- [16] BREGAR K. Indoor UWB positioning and position tracking data set [J]. Scientific Data, 2023, 10(1): 744.
- [17] IKOTUN A M, EZUGWU A E, ABUALIGAH L, et al. K-means clustering algorithms: A comprehensive review, variants analysis, and advances in the era of big data [J]. Information Sciences, 2023, 622: 178-210.
- [18] HASHEMI S E, GHOLIAN-JOUYBARI F, HAJIAGHAEI-KESHTELI M. A fuzzy C-means algorithm for optimizing data clustering [J]. Expert Systems with Applications, 2023, 227: 120377.
- [19] SHUTAYWI M, KACHOUIE N N. Silhouette analysis for performance evaluation in machine learning with applications to clustering [J]. Entropy, 2021, 23(6): 759.
- [20] ROS F, RIAD R, GUILLAUME S. PDBI: A partitioning davies-bouldin index for clustering evaluation [J]. Neurocomputing, 2023, 528: 178-199.
- [21] LYU Y, LIU S, GAO Y, et al. An ultra-wideband indoor localization algorithm with improved cubature kalman filtering based on sigmoid function [J]. Applied Sciences, 2024, 14(6): 2239.
- [22] MORAWSKA B, LIPINSKI P, LICHY K, et al. Transfer

learning-based UWB indoor localization using MHT-MDC and clusterization-based sparse fingerprinting [J]. Journal of Computational Science, 2022, 61: 101654.

- [23] SI M, WANG Y, SILJAK H, et al. A lightweight CIR-based CNN with MLP for NLOS/LOS identification in a UWB positioning system [J]. IEEE Communications Letters, 2023, 27(5): 1332-1336.
- [24] PASZEK K, GRZECHCA D. Using the LSTM neural network and the UWB positioning system to predict the position of low and high speed moving objects [J]. Sensors, 2023, 23(19): 8270.
- [25] LIU Q, YIN Z, ZHAO Y, et al. UWB LOS/NLOS identification in multiple indoor environments using deep learning methods [J]. Physical Communication, 2022, 52: 101695.
- [26] SUN J, SHI W, YANG Z, et al. Behavioral modeling and linearization of wideband RF power amplifiers using BiLSTM networks for 5G wireless systems [J]. IEEE Transactions on Vehicular Technology, 2019, 68(11): 10348-10356.
- [27] JIA B, LIU J, FENG T, et al. TTSL: An indoor localization method based on temporal convolutional network using time-series RSSI [J]. Computer Communications, 2022, 193: 293-301.
- [28] JIANG C, CHEN S, CHEN Y, et al. An UWB channel impulse response de-noising method for NLOS/LOS classification boosting [J]. IEEE Communications Letters, 2020, 24(11): 2513-2517.

作者简介



吴仕勋, 2012 年于华中师范大学获得博士学位, 现为重庆交通大学副教授, 主要研究方向为无线定位、神经网络定位及无线通信。

E-mail: wushixun333@163.com

Wu Shixun received Ph. D. degree from Central China Normal University in 2012. Now he is an Associate Professor at Chongqing Jiaotong University. His main research interests include wireless localization, neural network localization, and wireless communication.



王潇 (通信作者), 2021 年于重庆交通大学获得学士学位, 现为重庆交通大学硕士研究生, 主要研究方向为超宽带 (UWB) 室内定位及深度学习。

E-mail: wangxiao5656@126.com

Wang Xiao (Corresponding author) received his B. Sc. degree from Chongqing Jiaotong University in 2021. Now he is a M. Sc. candidate at Chongqing Jiaotong University. His main research interests include Ultra-Wideband (UWB) indoor positioning and deep learning.



蓝章礼, 2008 年于中国重庆大学获得博士学位, 现任重庆交通大学教授, 主要研究方向为数字图像处理、模式识别及交通信息处理。

E-mail: 385551137@qq.com

Lan Zhangli received his Ph. D. degree from Chongqing University in 2008. Now he is a Professor at Chongqing Jiaotong University. His main research interests include digital image processing, pattern recognition, and traffic information processing.



徐凯, 2006 年于重庆大学获得硕士学位, 现任重庆交通大学教授, 主要研究方向为模糊控制、自适应控制及智能算法。

E-mail: xkxjwx@hotmail.com

Xu Kai received his M. Sc. degree from Chongqing University in 2006. Now he is a Professor at Chongqing Jiaotong University. His main research interests include fuzzy control, adaptive control, and intelligent algorithms.



张森, 2020 年于英国约克大学获得博士学位, 现为重庆交通大学副教授, 主要研究方向为凸优化技术、智能反射面辅助无线网络。

E-mail: msczz@foxmail.com

Zhang Miao received his Ph. D. degree from the University of York in 2020. Now he is an Associate Professor at Chongqing Jiaotong University. His main research interests include convex optimization techniques, intelligent reflecting surface assisted wireless networks.



靳双, 2021 年于重庆大学获得博士学位, 现为重庆交通大学讲师, 主要研究方向为智能交通系统、网联自动驾驶及协同控制。

E-mail: 884580930@qq.com

Jin Shuang received his Ph. D. degree from Chongqing University in 2021. Now he is a Lecturer at Chongqing Jiaotong University. His main research interests include intelligent transportation systems, connected and automated vehicles, and cooperative control.