

基于对比学习的小样本室内定位方法^①



高秋生¹, 陈 明¹, 孟祥龙¹, 王九成¹, 张 磊¹, 李 琨²

¹(国网河北省电力有限公司信息通信分公司, 石家庄 050051)

²(南京南瑞信息通信科技有限公司, 南京 211106)

通信作者: 陈明, E-mail: 2586883440@qq.com

摘 要: 针对室内复杂电磁传输环境下现有的接收信号强度的定位方法依赖大量标签信息进行特征提取的局限性, 本文提出了一种基于对比学习的小样本室内定位方法. 该方法将来自同一位置的射频指纹视为正样本, 而不同位置的指纹则被视为负样本, 模型可以学习到一个能够区分不同位置射频指纹的高效距离度量, 从而更有效地提取射频指纹的特征. 同时在特征提取网络训练中设计了一个与物理距离有关的惩罚项空间感知损失, 确保模型在充分考虑物理空间约束下使得空间上接近的样本在特征空间中也更为接近, 从而得到一个健壮的特征提取器. 在保持预训练的特征提取器不变的条件下, 通过训练多层感知器来学习提取特征与相应位置坐标之间的映射关系, 从而得到终端位置定位网络. 仿真实验结果表明, 所提方法的定位性能与结合相位校准与 SSIM 数据增强的定位方法相比, 性能提升约 5%.

关键词: 室内定位; 接收信号强度; 小样本; 对比学习

引用格式: 高秋生, 陈明, 孟祥龙, 王九成, 张磊, 李琨. 基于对比学习的小样本室内定位方法. 计算机系统应用. <http://www.c-s-a.org.cn/1003-3254/10270.html>

Few-shot Indoor Localization Method Based on Contrastive Learning

GAO Qiu-Sheng¹, CHEN Ming¹, MENG Xiang-Long¹, WANG Jiu-Cheng¹, ZHANG Lei¹, LI Kun²

¹(State Grid Hebei Electric Power Company Information and Communication Branch, Shijiazhuang 050051, China)

²(Nanjing NARI Information & Communication Technology Co. Ltd., Nanjing 211106, China)

Abstract: To address the limitation that existing received signal strength (RSS)-based indoor localization methods rely on extensive labeled information for feature extraction in complex indoor electromagnetic transmission environments, this study proposes a few-shot indoor localization method based on contrastive learning. The method treats radio frequency (RF) fingerprints from the same location as positive samples, while fingerprints from different locations are considered negative samples. The model can learn an efficient distance metric for distinguishing RF fingerprints from different locations, thus enabling more effective extraction of RF fingerprint features. In addition, a penalty term related to physical distance, namely spatial-aware loss, is designed during feature extraction network training to ensure that the model adequately considers physical spatial constraints, so that spatially proximate samples are also closer in the feature space, resulting in a robust feature extractor. With the pre-trained feature extractor kept unchanged, a multi-layer perceptron (MLP) is trained to learn the mapping relationship between extracted features and corresponding location coordinates to form a terminal position localization network. Simulation experimental results show that the proposed method achieves a performance improvement of approximately 5% compared with the localization method combining phase calibration and SSIM data augmentation.

Key words: indoor localization; received signal strength (RSS); few-shot; contrastive learning

① 基金项目: 国网河北省电力有限公司科研项目 (kj2024-062)

收稿时间: 2025-12-15; 修改时间: 2026-01-19, 2026-03-27; 采用时间: 2026-04-03; csa 在线出版时间: 2026-08-21

随着互联网技术的快速发展和普及,基于位置信息的服务(location based service, LBS)^[1]在日常生活中的应用和需求也日益增加。尽管GPS等室外定位技术已经成熟并得到广泛应用,但它们无法在室内环境中提供准确的定位信息。大多数人的生活和工作都发生在室内,室内空间也是重要的商业和社交场所。因此,室内定位技术的发展变得不可避免。它为人们在室内环境中提供定位导航、位置搜索和服务推荐等功能,满足了人们对个性化和便捷性的需求。在LBS中,室内定位技术可以为用户提供精确的位置信息,使用户能够更好地导航、定位和查找所需的服务或设施。无论是在购物中心、医院、机场还是其他公共场所,室内定位技术都能帮助人们更轻松地找到目标位置,并提供有关周围环境的实用信息。

室内定位方法主要利用WiFi、蓝牙、超宽带(ultra wide band, UWB)、射频识别(radio frequency identification, RFID)、超声波和可见光等技术来估计实体(例如人或物体)的位置^[2]。根据定位原理,室内定位方法分为两大类^[2]:三角定位与指纹定位。三角定位方法基于三角形的几何性质来估计位置,通过测量移动对象与发射机(如WiFi接入点、GSM基站、蓝牙信标等)之间的距离或角度来进行定位。这些测量可以是接收信号强度(received signal strength, RSS)、到达时间(time of arrival, TOA)、到达角度(angle of arrival, AOA)等^[3-5]。指纹定位方法则通过建立地图或地标的指纹数据库来实现定位,它基于收集和存储不同位置的信号指纹^[6-8],例如WiFi信号强度、信道状态信息(channel state information, CSI)或其他可用的信号特征。在定位时,通过匹配实时采集的信号指纹与数据库中的指纹,从而确定位置。指纹定位方法在室内环境中具有较高的定位准确性和灵活性,但需要事先进行指纹数据库的构建。

目前,随着深度学习的发展,指纹定位方法得到了显著的改进和提升。在指纹定位领域,深度学习的应用为克服传统方法所面临的若干挑战提供了新的解决方案。一方面,深度学习能够自动学习和提取信号指纹中的关键特征。传统的指纹定位方法需要手动设计特征提取算法,这往往需要大量的专业知识和经验。而深度学习可以通过训练神经网络来自动学习和提取信号中的有用特征,大大减少了人工干预的需求,提高了定位的准确性和稳定性。另一方面,深度学习能够建立更复

杂和更强大的模型来处理指纹定位中的非线性关系。室内环境复杂多变,信号传播存在很多非线性效应,传统的线性模型往往难以捕捉到这些复杂性。而深度学习通过多层神经网络的组合和非线性激活函数的引入,能够更好地建模信号与位置之间的复杂关系,提高了定位的精度和鲁棒性。Gao等人^[9]开发了一个基于深度学习的图像处理框架,用于描述人类行为对周围WiFi信号的影响。通过利用无线电图像中丰富的颜色和纹理特征信息,以及深度学习网络的特征提取能力,提出的方案可以为分类器提供具有区分性的信息,从而提高定位和行为识别系统的性能。在ConFi系统中,Chen等人^[10]将来自多个天线的CSI组成多个图像,用于表示时域和频域上的CSI,将其作为卷积神经网络的输入,使用包含3个卷积层和2个全连接层的5层神经网络来处理这些CSI特征图像。然而,基于指纹的定位方法需要巨大的人力和时间成本,因此迫切需要更高效且经济的定位解决方案。2023年,Zheng等人^[11]提出了一种基于深度学习的混合RSS和CSI定位算法HRC,充分利用了粗粒度RSS进行指纹数据库的快速构建和细粒度CSI的丰富多径信息。同时,王逸等人^[12]根据CSI的簇分布特点,利用K-means算法对所有定位点内的CSI数据聚类后得到多个簇的CSI数据并建立多个簇指纹库,定位平均误差0.95 m。刘帅等人^[13]联合定位环境参考点的幅度差和相位差信息构建指纹,引入改进的基于概率的指纹匹配算法进行定位。张力等人^[14]提出一种基于深度残差收缩网络的定位与行为联合识别方法,在暗室、会议室和走廊这3种场景下的室内定位的平均准确率达到97.29%。李新春等人^[15]通过高维数据的PCA算法提取子数据集的特征以减少冗余信息、提高不同位置指纹的区分性,最后利用特征指纹训练GRNN模型^[16]。次年,该团队采用果蝇优化算法改进的GBDT算法训练降维后的数据以提高CSI指纹的可靠性和稳定性^[17]。周牧等人^[18,19]将基于平行因子分析模型的张量分解算法和交替最小二乘迭代算法相结合以减少CSI中环境噪声的干扰,在定位误差4 m内的置信概率为94.88%。周炳朋等人^[20]提出了一种指纹推理模型校准方法,通过将高斯赋权模型的校准问题转化为随机优化问题,利用连续凸函数逼近技术解决了非凸优化难题,显著提升了指纹匹配的精度。龙良等人^[21]针对CSI数据的时频特性,提出了一种改进MixNet的定位方法,通过引入坐标注意力机制(coor-

dinate attention) 来增强网络对 CSI 图像中关键纹理特征的关注度, 从而在复杂环境下实现了更高精度的指纹匹配. 丁艳召等人^[22]设计了基于 MCR-Net 的 CSI 指纹定位模型, 通过巧妙结合残差连接 (residual connection) 与密集连接 (dense connection) 策略, 有效解决了深层网络训练中的梯度消失问题, 实现了对 CSI 深层细粒度特征的高效提取. Xu 等人^[23]在 2024 年提出了基于 Swin Transformer 的指纹定位系统 Swin-Loc, 利用自注意力机制自适应地聚合 MIMO-CSI 的时频特征, 在复杂多径环境下显著提升了定位精度. Zhang 等人^[24]在 2024 年提出了一种面向 5G 室内定位的半监督对比学习框架. 通过最大化不同信道条件下 CSI 表征的一致性, 该方法在小样本场景下实现了鲁棒的定位性能. Wei 等人^[25]在 2022 年提出了一种基于相位校准与结构相似度增强的免携带设备定位方法. 通过对 CSI 原始相位进行线性校准并引入基于 SSIM 的数据增强技术, 该方法在减少标注数据依赖的同时, 有效提升了复杂室内环境下的指纹定位精度.

尽管指纹定位在精度和鲁棒性方面都有着不错的表现, 但该方法对指纹库的大小具有较强的依赖性^[26]. 建立一个大规模的指纹库需要耗费大量的时间和资源来收集、标注和维护指纹数据. 因此如何在少量指纹的条件下, 构建出一个低成本、高精度的室内定位系统是本文需要解决的问题. 针对上述问题, 本文提出一种基于对比学习的小样本室内定位方法, 该方法将来自同一位置的射频指纹视为正样本, 而不同位置的指纹则被视为负样本, 模型可以学习到一个能够区分不同位置射频指纹的高效距离度量, 从而更有效地提取射频指纹的特征. 并且在特征提取网络训练中设计了一个与物理距离有关的惩罚项空间感知损失, 确保模型在充分考虑物理空间约束下使得空间上接近的样本在特征空间中也更为接近, 从而得到一个健壮的特征提取器. 在保持预训练的特征提取器不变的条件下, 通过训练多层感知器来学习提取特征与相应位置坐标之间的映射关系, 从而得到终端位置定位网络. 实验结果表明, 所提方法的定位性能与结合相位校准与 SSIM 数据增强的定位方法相比性能提升约 5%.

1 系统模型

图 1 中给出了本文使用 WiFi 搭建的实验平台, 包括 WiFi 信号发射机和在不同位置的接收机. CSI 指纹

定位利用了室内环境中无线信号传播的独特属性. 当信号穿越环境时, 它们与墙壁、门和家具等障碍物发生交互, 从而产生多径效应. 这些交互改变了信号的特性, 通过测量这些变化, 可以为特定位置创建一个“指纹”. 这种指纹足够独特, 可以用来区分室内不同的位置, 从而可以用于定位. 本文实验在教学大楼中进行, 如图 1 所示共设置了两类典型室内定位场景. 其中, 图 1(a) 为室内定位场景图, 图 1(b) 为多障碍物机房定位场景图. 图 1(a) 场景主要由走廊、房间和大厅这 3 个区域组成. 图 1(b) 场景为教学楼内机房环境, 场景内分布有大量障碍物, 空间结构更为复杂, 信号传播过程中更容易受到遮挡、多径反射及散射等因素的影响, 因此可用于进一步验证不同算法在复杂障碍环境下的定位性能. 本文将接收机的测量信号分为训练集和不同位置上的测试集合, 以验证本文所提算法的有效性.




图 1 场景图

图 2 给出了所提算法的架构, CSI 指纹定位方法包括两个主要阶段: 离线训练阶段和在线预测阶段. 离线训练阶段, 系统在预定义的参考点 (reference points, RPs) 上收集 CSI 值, 并创建一个 CSI 指纹数据库. 这通常需要在多个参考点上进行多次测量, 以确保获得的数据的可靠性和稳定性. 收集到的 CSI 数据通过预处

理构成 CSI 图像. 在线预测阶段, 无线设备收集当前位置的 CSI 值通过训练的定位网络预测终端位置坐标. 通过离线阶段构建一个健壮且全面的 CSI 指纹数据库, 并在在线阶段使用高效的匹配算法, 可以实现准确的位置估计. 本文的工作的重点就是在小样本场景下通过对比学习网络和设计的一个与物理距离有关的惩罚项空间感知损失参量训练健壮的特征提取器, 要提升终端的室内定位精度.




图2 所提算法的框架

评估室内定位系统时, 通常会使用一系列指标来量化其性能, 包括定位精度指标以及与神经网络复杂度相关的因素^[2]. 定位精度指标: (1) 定位误差的均方根误差 (root mean squared error, RMSE) 通常表示为:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_{t,i} - P_{e,i})^2} \quad (1)$$

其中, N 是样本数量, $P_{t,i}$ 是第 i 个样本的真实位置, $P_{e,i}$ 是对应的估计位置. (2) 定位误差的累积分布函数 (cumulative distribution function, CDF), CDF 衡量了定位误差在一定范围内的累积概率分布. 通常通过绘制误差的累积分布曲线来表示. (3) 最大误差指在 N 个测试样本中, 定位误差的最大值. 在累积分布函数 (CDF) 图中, 最大误差对应累积概率为 1 时的横坐标值. 该指标反映了定位系统的可靠性边界及最坏情况下的表现. 中位数误差指将所有样本的定位误差按升序排列后, 处于 50% 分位数处的误差值, 即 CDF 曲线中纵坐标为 0.5 时对应的横坐标值. 相较于 RMSE, 中位数误差对离群点不敏感, 能更客观地反映系统在常规状态下的平均定位水平.

网络复杂度衡量指标: (1) 参数量: 表示神经网络中可训练参数的数量, 包括权重和偏差. 参数量通常与网络的深度和宽度有关, 更深更宽的网络通常具有更多的参数; (2) 浮点数运算量 (floating-point operations):

神经网络的计算复杂度通常以浮点数运算的总次数来表示. 这种复杂度与网络的层数、神经元数量和连接密度直接相关. 越复杂的网络往往需要更多的浮点数运算. 这些评价指标和神经网络复杂度因素可以用于评估室内定位系统的性能和复杂性. 在实际应用中, 需要权衡这些因素, 以选择适合特定任务和资源限制的定位算法和网络结构.

2 基于对比学习的小样本室内定位方法

本文所提算法是基于对比学习方法, 通过 CSI 射频指纹训练特征提取网络和终端定位网络来实现终端的位置预测.

2.1 CSI 指纹构建方法

在商业环境中, 通常采用 CSI Tool 与 Intel 5300 网络适配器来获得 CSI 的测量值. 本文也采用了这种方法来收集 CSI 测量值. 任意位置的 CSI 测量值可以表示为一个的矩阵:

$$H = \begin{bmatrix} H_1^1(f_1) & \cdots & H_n^1(f_1) & \cdots & H_N^1(f_1) \\ H_1^2(f_2) & \cdots & H_n^2(f_2) & \cdots & H_N^2(f_2) \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ H_1^L(f_S) & \cdots & H_n^L(f_S) & \cdots & H_N^L(f_S) \end{bmatrix} \quad (2)$$

其中, $H_n^l(f_s)$ 表示第 l 个天线对的第 S 个子载波的第 n 个 CSI 测量值. 为了进一步分析和处理这些数据, 我们将矩阵 H 分解为两个部分: 幅度矩阵 H_a 和相位矩阵 H_p . 幅度矩阵 H_a 包含了 H 中每个元素的模, 相位矩阵 H_p 则包含了相应元素的相位, 本文的算法中只用到了幅度矩阵 H_a . 由于商用 WiFi 设备的硬件缺陷和环境中的电磁干扰, 获取的 CSI 数据中会含有许多噪声成分, 因此对数据进行处理和优化是必要的. 预处理的主要目的是消除或减少噪声, 提高 CSI 数据的质量和可信度.

2.2 构造 CSI 图像

由第 2.1 节可知, 幅度 H_a 是大小为 $d \times N$ 的矩阵, 经过第 2.1 节的预处理后, 假设 $d = S \times L$, 其中子载波 30 个, 接收天线 3 根, 测量次数 $N = 1200$. 我们将每 30 个测量值组成一个 90×30 大小的矩阵, 总共得到 40 个矩阵. 然后, 使用 Matlab 中的 `imwrite` 函数将这些矩阵映射到 jet 颜色域中, 这样就可以获得幅度与相位的 RGB 图像. 由于该图像是 RGB 图像, 所以它有 3 个颜色通道, 我们将幅度图与相位图拼接起来构成 CSI 指纹图 $s_{l,k}$, 其大小为 $3 \times 30 \times 30$. 为了方便理解, 图 3 详细画出

了 CSI 指纹图的构造方式.




图3 CSI 指纹图的构造方式

2.3 特征提取网络和定位网络的离线训练

(1) 正负样本构造与对比学习损失

图4展示了基于对比学习的小样本室内定位方法的总体框架. 基于对比学习的定位需要两个阶段, 包括训练特征提取网络和训练定位网络. 考虑一个包含 L 个参考点的 CSI 数据集 $\{s_{l,k} | l \in [1, L], k \in [1, K]\}$, 其中每个参考点具有 K 个样本. 每个样本 $s_{l,k}$ 都对应第2.2节中的一张 CSI 图像. 在此框架下, 复杂环境中信号在传播过程中会产生显著的多径效应. 对于特定位置 L_p 的信道响应, 其物理特性可建模为信道冲击响应 (channel impulse response, CIR):

$$h(t, L_p) = \sum_{i=1}^N a_i e^{j\phi_i} \delta(t - \tau_i) \quad (3)$$

其中, N 为多径总数, a_i 、 ϕ_i 和 τ_i 分别表示第 i 条路径的幅度、相位和时延. 正样本构造逻辑即当采样点处于同一物理位置 L_p 时, 由于室内静态障碍物对信号的反射和散射几何结构保持一致, 信号经历的多径剖面具有极高的空间相干性. 将同一位置的不同采样视为正样本, 旨在让特征提取器学习忽略由硬件噪声或环境动态变化引起的随机扰动, 提取出该位置固有的结构化特征. 负样本构造逻辑是由于室内环境复杂, 微小的位置偏移会导致各多径分量的相位 ϕ_i 发生剧烈变化, 产生相干干涉效应, 使得合成信号的幅度矩阵呈现出显著的非线性差异. 通过对比负样本, 模型能够学习到区分不同物理空间的敏感特征. 在特征提取网络的训练过程中, 我们的目标是通过最大化正样本对 $s_{l,k}$ 和 $s_{l',k'}$ 之间的相似性来训练特征提取器 $F(\cdot)$. 通过对比学习学到的特征不依赖于标签, 因此可以更准确地捕捉样本之间的潜在关系. 在定位网络的训练过程中, 保持预训练的特征提取器不变, 只训练多层感知器. 输入包括样本以及其对应的二维坐标 $(s_{l,k}, c_l)$, 用于训练将输入数据映射到位置坐标的定位模型.

值得注意的是, 在对比学习的传统框架中, 正样本对通常由相同实例的两种不同数据增强视图组成. 这

确保了在语义上, 正样本具有一致性, 但在微观特征上可能有所差异. 然而, 当我们将对比学习的概念引入到室内定位问题中时, 提出了一个新的定义方式: 基于物理接近性选择正样本. 在此背景下, 正样本不仅是由数据增强策略产生的相同样本的两个视图. 相反, 由于其在物理空间的邻近性, 两个不同的样本可能被认为是语义上相似的.




图4 基于对比学习的小样本室内定位方法总体框架

如图5所示, 本文的定位网络采用了基于对比学习的方法, 并受到了 SimSiam 架构的启发, 其主要包括3个部分: 特征提取器 $F(\cdot)$ 、预测器 $P(\cdot)$ 和多层感知器 $H(\cdot)$. $F(\cdot)$ 包括4个卷积块和2个全连接层, $P(\cdot)$ 包括2个全连接层, $H(\cdot)$ 包括1个全连接层.




图5 基于对比学习的定位网络的架构

我们的目标是最大化正样本对 $s_{l,k}$ 和 $s_{l',k'}$ 之间的相似性, 可以通过最小化它们之间的负余弦相似性来实现:

$$d(p_1, z_2) = -\frac{p_1}{\|p_1\|_2} \cdot \frac{z_2}{\|z_2\|_2} \quad (4)$$

$$p_1 = P(F(s_{l,k})), p_2 = P(F(s_{l',k'})) \quad (5)$$

$$z_1 = F(s_{l,k}), z_2 = F(s_{l',k'}) \quad (6)$$

其中, $\|\cdot\|_2$ 表示 l_2 范数. 在对比学习过程中, 对称形式的损失可以写成:

$$\mathcal{L}_{cl} = \frac{1}{2}d(p_1, z_2) + \frac{1}{2}d(p_2, z_1) \quad (7)$$

(2) 空间感知损失函数设计

考虑到物理空间信息与信号表征之间往往存在复杂的非线性映射关系, 简单的线性约束难以精确刻画这一特性. 针对这一问题, 我们在上述损失中引入一种基于可逆非线性映射的双向一致性约束损失函数.

首先, 为了统一量纲, 我们分别对样本对 $(s_{l,k}, s_{l',k'})$ 的物理空间距离 d_s 和特征表示的欧氏距离 $\|z_1 - z_2\|_2$ 进行归一化处理:

$$\bar{d}_s = \frac{d_s(s_{l,k}, s_{l',k'})}{D_{\max}} \quad (8)$$

$$\bar{d}_z = \frac{\|z_1 - z_2\|_2}{Z_{\max}} \quad (9)$$

其中, $D_{\max}$ 和 $Z_{\max}$ 分别表示物理空间和特征空间中的最大距离, 确保归一化后的距离值位于 $[0, 1]$ 区间. 在此基础上, 空间感知损失 $\mathcal{L}_s$ 定义为物理距离与特征距离在非线形映射下的双向误差之和:

$$\mathcal{L}_s = (\bar{d}_s - \varphi(\bar{d}_s))^2 + (\bar{d}_s - \varphi^{-1}(\bar{d}_z))^2 \quad (10)$$

为了模拟物理空间相近则特征相似、物理空间变远则特征差异非线性增大的特性, 我们定义 $\varphi(\cdot)$ 为一个严格单调递增且可逆的非线性映射函数及其逆函数:

$$\varphi(x) = 1 - e^{-\beta x} \quad (11)$$

$$\varphi^{-1}(x) = -\frac{1}{\beta} \ln(1 - x) \quad (12)$$

其中, $\beta > 0$ 为调节系数. 该损失函数通过 φ 和 φ^{-1} 建立了物理空间与特征空间之间的双向约束机制: 前一项 $(\bar{d}_s - \varphi(\bar{d}_s))^2$ 确保特征距离随物理距离非线性增长; 后一项 $(\bar{d}_s - \varphi^{-1}(\bar{d}_z))^2$ 则作为正则化项, 防止特征空间发生塌缩. 这种双向非线性映射能够更深层次地挖掘信

号与空间的内在拓扑关系, 提升模型对空间变化的感知能力.

所以, 最终的损失函数可以定义为:

$$\mathcal{L}_{\text{total}} = \mathcal{L}_{cl} + \lambda \mathcal{L}_s \quad (13)$$

其中, λ 是一个权重参数, 用于平衡两种损失.

(3) 定位网络训练

保持预训练的特征提取器不变, 只训练多层感知器来学习提取特征与相应位置坐标之间的映射关系. 用于训练定位网络的损失函数可以写成:

$$\mathcal{L}_p = \frac{1}{B} \sum_{i=1}^B \sqrt{(x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2} \quad (14)$$

其中, B 表示批量大小, (x_i, y_i) 和 $(\hat{x}_i, \hat{y}_i)$ 分别表示真实和估计坐标. 接收机接收信号 CSI, 最后将 CSI 图像化预处理, 送到训练得到的定位网络预测终端的位置.

3 实验分析

如图 6 所示, 通过 t-分布式随机邻近嵌入 (t-distributed stochastic neighbor embedding, t-SNE) 方法, 可以深入地观察到原始数据集的分布特性以及使用对比学习后得到的特征表示. 这种可视化显示了在应用对比学习方法后, 特征的聚类趋势明显得到了加强. 具体来说, 同一类别的数据点在特征空间中更加紧凑地聚集在一起, 而不同类别之间的间隔也变得更加明显. 这一点充分证明了对比学习的能力, 即强化数据特征的内部相似性, 同时增强不同类别特征的可区分性, 从而在聚类和分类任务上达到了卓越的性能.

3.1 小样本下的定位性能

从表 1 的实验结果可以观察到, 无论是否采用空间感知损失, 模型的定位性能随着训练集大小的增加而得到提升. 具体来说, 使用空间感知损失的方法在所有训练集大小设置下均表现优于未使用空间感知损失的方法. 例如, 当样本数量是 375 时, 使用空间感知损失得到的定位误差为 1.41 m, 而不使用的误差为 1.50 m, 这显示了使用空间感知损失有 0.09 m 的优势. 随着训练样本数量的增加, 这一优势逐渐缩小, 但始终存在. 这些结果充分证明了空间感知损失在室内定位任务中的有效性. 特别是小样本下, 空间感知损失能有效增强模型的学习性能.

当样本数量是 375 时, 图 7 给出了本文提出的带有空间感知损失的对比学习算法、文献[25]方法、基

于 LSTM 网络的方法以及基于 CNN 网络的方法性能比较图。在 CDF 概率 80% 下, 本文所提算法的定位误差大约在 2.1 m, 而文献[25]所提方法约为 2.3 m, LSTM 和 CNN 网络分别为 2.5 m 和 2.6 m。实验数据表明, 在相同误差条件下, 本文算法的累积概率相较文献[25]方法提高了约 5%。在 CDF 概率 90% 下, 本文所提算法的定位误差大约在 2.7 m, 而文献[25]所提方法约为 2.85 m, LSTM 和 CNN 网络分别为 2.9 m 和 3.05 m。相较于文献[25]方法, 本文算法在 CDF 90% 条件下精度提升约 10%。相较于传统深度学习网络, 本文算法的精度大约提升了 15%。




图6 t-SNE 可视化图

表1 不同样本数量下各算法的定位误差 (m)

算法	375	750	1500
本文算法 ($\mathcal{L}_{cl}$)	1.50	1.43	1.31
本文算法 ($\mathcal{L}_{total}$)	1.41	1.37	1.28
LSTM	1.92	1.72	1.50
CNN	2.23	1.91	1.78
中位数误差	1.25	1.17	1.04
最大误差	3.56	3.41	3.23
文献[25]	1.61	1.50	1.35

图8给出了多障碍物机房定位场景下, 训练集大小为 375 时各算法的 CDF 性能比较。在 CDF 概率 80%

下, 本文所提算法的定位误差约为 1.95 m, 而文献[25]方法约为 2.25 m, LSTM 和 CNN 网络分别为 2.4 m 和 2.5 m。在 CDF 概率 90% 下, 本文所提算法的定位误差约为 2.6 m, 文献[25]方法约为 2.7 m, LSTM 和 CNN 网络分别为 2.8 m 和 2.95 m。在 CDF 90% 条件下相较文献[25]方法精度提升约 5%。与室内场景相比, 由于该场景中空间特征分布更具辨识度, 各算法的整体性能较图7均有约 5% 的提升。但经过对比本文所提算法仍然保持着最优的定位性能。




图7 室内场景不同算法训练集大小为 375 的累积分布函数




图8 多障碍物场景不同算法训练集大小为 375 的累积分布函数

3.2 算法复杂度分析

(1) 模型参数量

本文设计的基于对比学习的小样本室内定位模型由 3 个主要组成部分构成: 特征提取器、预测器以及多层感知器。如表2所示, 经过详细的参数量计算, 特征提取器占据了绝大多数的参数, 达到 4.65M, 而预测

器有 0.39M 的参数. 多层感知器作为模型中相对较小的一部分, 仅包含 0.07M 的参数. 综合这 3 个部分, 整个模型的总参数量为 5.11M.

表 2 模型参数量 (M)

组成部分	参数量
特征提取器	4.65
预测器	0.39
多层感知器	0.07
总计	5.11

(2) 浮点数运算量

本文设计的基于对比学习的小样本室内定位模型, 当进行位置判断即在推断阶段时, 需要对输入图片进行一定量的浮点数运算. 如表 3 所示, 特征提取器扮演了主要的计算角色, 需要 0.52G 的浮点数运算量来提取图片的关键特征. 而在此阶段, 预测器不参与运算, 因此不增加额外的计算负担. 多层感知器只需额外 0.1M 的浮点数运算量. 综上, 为判断一张图片的位置, 整个模型总计需要进行约 0.52G 的浮点数运算.

表 3 浮点数运算量

组成部分	浮点数运算量
特征提取器	0.52G
多层感知器	0.1M
总计	0.52G

4 结论与展望

本文针对室内复杂电磁传输环境下现有的接收信号强度的定位方法依赖大量标签信息进行特征提取的局限性, 提出了一种基于对比学习的小样本室内定位方法, 该方法将来自同一位置的射频指纹视为正样本, 而不同位置的指纹则被视为负样本, 模型可以学习到一个能够区分不同位置射频指纹的高效距离度量, 从而更有效地提取射频指纹的特征. 仿真结果表明, 相同场景下所提方法的定位性能与基于 LSTM 和 CNN 网络的定位方法相比性能提升 15%, 相较文献[25]方法性能提高了约 5%. 未来的研究方向为以下 3 方面. (1) 多模态数据融合: 在小样本情境下, 充分利用多种传感器的数据是提高模型性能的关键. (2) 迁移学习在小样本室内定位中的应用: 对于小样本 CSI 室内定位, 迁移学习提供了一种有效地利用其他大数据集知识的方法. 由于室内环境经常发生变化, 小样本数据可能无法捕捉所有的变化. (3) 实时性与动态环境适应: 为了满足

实时性的需求, 需要研究如何在动态变化的环境中实现快速且准确的室内定位方法, 这涉及模型的在线学习、实时数据处理以及动态环境感知等技术.

参考文献

- 1 Mostafa S, Harras KA, Youssef M. A survey of indoor localization systems for multi-floor environments. *IEEE Access*, 2025, 13: 146396–146432. [doi: [10.1109/ACCESS.2025.3599785](https://doi.org/10.1109/ACCESS.2025.3599785)]
- 2 Sesyuk A, Ioannou S, Raspopoulos M. A survey of 3D indoor localization systems and technologies. *Sensors*, 2022, 22(23): 9380. [doi: [10.3390/s22239380](https://doi.org/10.3390/s22239380)]
- 3 Yang T, Cabani A, Chafouk H. A survey of recent indoor localization scenarios and methodologies. *Sensors*, 2021, 21(23): 8086. [doi: [10.3390/s21238086](https://doi.org/10.3390/s21238086)]
- 4 Yadav VK, Verma S, Venkatesan S. Linkable privacy-preserving scheme for location-based services. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23(7): 7998–8012. [doi: [10.1109/TITS.2021.3074974](https://doi.org/10.1109/TITS.2021.3074974)]
- 5 Zafari F, Gkelias A, Leung KK. A survey of indoor localization systems and technologies. *IEEE Communications Surveys & Tutorials*, 2019, 21(3): 2568–2599. [doi: [10.1109/COMST.2019.2911558](https://doi.org/10.1109/COMST.2019.2911558)]
- 6 Sari R, Zayyani H. RSS localization using unknown statistical path loss exponent model. *IEEE Communications Letters*, 2018, 22(9): 1830–1833. [doi: [10.1109/LCOMM.2018.2849963](https://doi.org/10.1109/LCOMM.2018.2849963)]
- 7 Nguyen NH, Doğançay K. Optimal geometry analysis for multistatic TOA localization. *IEEE Transactions on Signal Processing*, 2016, 64(16): 4180–4193. [doi: [10.1109/TSP.2016.2566611](https://doi.org/10.1109/TSP.2016.2566611)]
- 8 Doğançay K, Hmam H. Optimal angular sensor separation for AOA localization. *Signal Processing*, 2008, 88(5): 1248–1260. [doi: [10.1016/j.sigpro.2007.11.013](https://doi.org/10.1016/j.sigpro.2007.11.013)]
- 9 Bahl P, Padmanabhan VN. RADAR: An in-building RF-based user location and tracking system. *Proceedings of the 9th Annual Joint Conference of the IEEE Computer and Communications Societies*. Tel Aviv: IEEE, 2000. 775–784.
- 10 Hu XK, Shang JG, Gu FQ, *et al.* Improving Wi-Fi indoor positioning via AP sets similarity and semi-supervised affinity propagation clustering. *International Journal of Distributed Sensor Networks*, 2015, 2025: 109642.
- 11 Sorour S, Lostanlen Y, Valaee S, *et al.* Joint indoor localization and radio map construction with limited deployment load. *IEEE Transactions on Mobile Computing*, 2015, 14(5): 1031–1043. [doi: [10.1109/TMC.2014.2343636](https://doi.org/10.1109/TMC.2014.2343636)]

- 12 Gao QH, Wang J, Ma XR, *et al.* CSI-based device-free wireless localization and activity recognition using radio image features. *IEEE Transactions on Vehicular Technology*, 2017, 66(11): 10346–10356. [doi: [10.1109/TVT.2017.2737553](https://doi.org/10.1109/TVT.2017.2737553)]
- 13 Chen H, Zhang YF, Li W, *et al.* ConFi: Convolutional neural networks based indoor Wi-Fi localization using channel state information. *IEEE Access*, 2017, 5: 18066–18074. [doi: [10.1109/ACCESS.2017.2749516](https://doi.org/10.1109/ACCESS.2017.2749516)]
- 14 Zheng Y, Liu JY, Sheng M, *et al.* Exploiting fingerprint correlation for fingerprint-based indoor localization: A deep learning-based approach. In: Tiku S, Pasricha S, eds. *Machine Learning for Indoor Localization and Navigation*. Cham: Springer, 2023. 201–237.
- 15 王逸, 裴生雷, 王煜. 基于 CSI 和 K-means-SVR 的多指纹库室内定位方法. *计算机应用*, 2023, 43(5): 1636–1640. [doi: [10.11772/j.issn.1001-9081.2022081162](https://doi.org/10.11772/j.issn.1001-9081.2022081162)]
- 16 刘帅, 王旭东, 吴楠. 一种基于卷积神经网络的 CSI 指纹室内定位方法. *工程科学学报*, 2021, 43(11): 1512–1521. [doi: [10.13374/j.issn2095-9389.2020.12.09.003](https://doi.org/10.13374/j.issn2095-9389.2020.12.09.003)]
- 17 张力, 常俊, 武浩, 等. 深度残差收缩网络下的定位与行为联合识别. *计算机工程与应用*, 2022, 58(21): 205–212. [doi: [10.3778/j.issn.1002-8331.2105-0129](https://doi.org/10.3778/j.issn.1002-8331.2105-0129)]
- 18 李新春, 黄朝晖. 基于聚类的 PCA 和 GRNN 的 CSI 指纹定位算法. *重庆邮电大学学报 (自然科学版)*, 2021, 33(3): 449–457. [doi: [10.3979/j.issn.1673-825X.201904190156](https://doi.org/10.3979/j.issn.1673-825X.201904190156)]
- 19 李新春, 赵忠婷, 于洪仕. 基于局部线性嵌入和梯度提升决策树的信道状态信息室内指纹定位算法研究. *激光与光电子学进展*, 2022, 59(2): 0215008.
- 20 周炳朋, 陈光森, 王鑫. 面向可见光无线定位的指纹推理模型校准. *电子学报*, 2024, 52(6): 1925–1937. [doi: [10.12263/DZXB.20230329](https://doi.org/10.12263/DZXB.20230329)]
- 21 龙良, 王小鹏, 李岗, 等. 改进 MixNet 的 CSI 图像指纹室内定位方法. *全球定位系统*, 2024, 49(3): 57–64. [doi: [10.12265/j.gnss.2023198](https://doi.org/10.12265/j.gnss.2023198)]
- 22 丁艳召, 尚俊娜, 鲁春冬. 基于 MCR-Net 模型的 CSI 指纹定位. *导航定位与授时*, 2025, 12(6): 103–111. [doi: [10.19306/j.cnki.2095-8110.2025.06.010](https://doi.org/10.19306/j.cnki.2095-8110.2025.06.010)]
- 23 Wang XP, Guan K, He DP, *et al.* Resilient 3D indoor localization using a masked Transformer encoder with multi-band CSI fingerprint. *IEEE Transactions on Wireless Communications*, 2026, 25: 4391–4404. [doi: [10.1109/TWC.2025.3610624](https://doi.org/10.1109/TWC.2025.3610624)]
- 24 Xu XD, Zhu FZ, Han SJ, *et al.* Swin-Loc: Transformer-based CSI fingerprinting indoor localization with MIMO ISAC system. *IEEE Transactions on Vehicular Technology*, 2024, 73(8): 11664–11679. [doi: [10.1109/TVT.2024.3381433](https://doi.org/10.1109/TVT.2024.3381433)]
- 25 Wei W, Yan J, Wu XF, *et al.* CSI fingerprinting for device-free localization: Phase calibration and SSIM-based augmentation. *IEEE Wireless Communications Letters*, 2022, 11(6): 1137–1141. [doi: [10.1109/LWC.2022.3159104](https://doi.org/10.1109/LWC.2022.3159104)]
- 26 周牧, 龙玥辛, 蒲巧林, 等. 基于 CSI 张量分解的室内 Wi-Fi 指纹定位方法. *通信学报*, 2021, 42(11): 159–171.

(校对责编: 李慧鑫)