

## 基于孪生图卷积神经网络的小样本迁移学习室内指纹定位

施政<sup>1</sup>, 顾浩<sup>2</sup>, 黄浩<sup>1</sup>, 王禹<sup>1</sup>, 夏文超<sup>1,3</sup>, 赵海涛<sup>3,4</sup>, 朱洪波<sup>1,3</sup>

(1. 南京邮电大学通信与信息工程学院, 江苏 南京 210003; 2. 东南大学集成电路学院, 江苏 南京 211189;  
3. 江苏省无线通信与物联网重点实验室, 江苏 南京 210003; 4. 南京邮电大学物联网学院, 江苏 南京 210003)

**摘要:** 基于射频信号的室内定位技术是第六代无线通信系统中的重要研究方向之一。随着人工智能的发展, 基于深度学习的室内指纹定位方法在定位性能上得到了显著提升。然而, 这类方法仍面临以下挑战, 包括射频数据采集时间长、标注成本高, 导致现有深度学习算法在不同场景下的环境泛化能力差。针对该问题, 提出了一种基于孪生图卷积神经网络 (Siamese GCN, siamese graph convolutional network) 的小样本迁移学习室内指纹定位方法。该技术结合 Siamese GCN 模型与基于最大均值差异的领域自适应方法, 仅需在当前环境中采集少量信道状态信息样本, 即可复用其他环境中已训练好的模型权重, 从而显著降低新环境下的数据采集与标注成本。为验证所提方法的有效性, 在实验室和走廊两个典型的室内场景下采集了真实的环境数据。实验结果表明, 所提的迁移学习方法在仅使用 30% 的标注样本的情况下, 仍能实现较好的定位性能。

**关键词:** 孪生图卷积神经网络; 室内定位; 迁移学习; 信道状态信息

**中图分类号:** TN911.7

**文献标志码:** A

**doi:** 10.11959/j.issn.2096-3750.2025.00540

## Siamese GCN empowered fingerprinting indoor localization using few-shot transfer learning

SHI Zheng<sup>1</sup>, GU Hao<sup>2</sup>, HUANG Hao<sup>1</sup>, WANG Yu<sup>1</sup>, XIA Wenchao<sup>1,3</sup>, ZHAO Haitao<sup>3,4</sup>, ZHU Hongbo<sup>1,3</sup>

1. School of Communications and Information Engineering, Nanjing University of Posts and Telecommunications, Nanjing 210003, China

2. School of Integrated Circuits, Southeast University, Nanjing 211189, China

3. Jiangsu Province Key Laboratory of Wireless Communication and Internet of Things, Nanjing 210003, China

4. School of Internet of Things, Nanjing University of Posts and Telecommunications, Nanjing 210003, China

**Abstract:** Radio frequency (RF)-based indoor positioning technology is recognized as one of the important research directions in the sixth generation wireless communication (6G) systems. With the advancement of artificial intelligence (AI), deep learning-based indoor fingerprint localization methods have achieved significant improvements in positioning performance. However, these methods still face the following challenges, including lengthy RF data collection periods and high annotation costs, which lead to poor environmental generalization capability of existing deep learning algorithms across different scenarios. To address this issue, a few-shot transfer learning indoor fingerprint localization method based on a Siamese graph convolutional network (Siamese GCN) was proposed. The Siamese GCN model was combined with a maximum mean discrepancy-based domain adaptation approach, requiring only a small number of channel state information samples to be collected in the current environment. Pre-trained network weights from other environments were re-used, significantly reducing data collection and annotation costs in new environments. To validate the effectiveness of the proposed method, real environmental data were collected in two typical indoor scenarios: a laboratory and a corridor.

收稿日期: 2025-09-28; 修回日期: 2025-11-17

通信作者: 朱洪波, zhb@njupt.edu.cn

基金项目: 国家自然科学基金资助项目 (No. 62274096); 江苏省自然科学基金资助项目 (No. BK20240621)

**Foundation Items:** The National Natural Science Foundation of China (No. 62274096), Natural Science Foundation of Jiangsu Province (No. BK20240621)

Experimental results demonstrated that the proposed transfer learning method achieved satisfactory localization performance using only 30% of the labeled samples.

**Key words:** Siamese GCN, indoor localization, transfer learning, channel state information

## 0 引言

室内定位是第六代无线通信（6G, 6th generation mobile communication）系统的关键功能之一<sup>[1-2]</sup>。室内定位技术支持多种应用场景，如在购物中心提供精确的导航服务、在智能工厂实现无缝跟踪<sup>[3]</sup>。当前的室内定位解决方案形式多样，包括基于蓝牙低功耗（BLE, bluetooth low energy）、长期演进（LTE, long term evolution）以及Wi-Fi技术的方案<sup>[4-5]</sup>。在各类定位方法中，基于信号指纹的方法，包括接收信号强度指示（RSSI, received signal strength indicator）<sup>[6]</sup>和信道状态信息（CSI, channel state information）<sup>[7]</sup>，通常被认为是实现高精度室内定位的有效途径。

近年来，深度学习（DL, deep learning）被广泛应用于无线通信领域。相应地，基于DL的指纹定位系统<sup>[8]</sup>被提出，用于利用CSI实现室内定位。在文献[9]中，作者从多输入多输出（MIMO, multiple input multiple output）链路中采集CSI数据，并采用基于深度学习的概率融合方法以提高定位精度。然而，基于DL的指纹定位方法面临的一个关键挑战是数据标注问题。构建基于DL的指纹定位系统，其中的核心环节是收集足够的训练数据。构建指纹数据库所需的大量标注样本，其收集过程耗时且代价高昂。此外，指纹数据库与采集环境高度相关，在每一个新环境中都需要重新采集独立的新指纹样本<sup>[10]</sup>。

针对上述数据标注成本高的问题，迁移学习（TL, transfer learning）<sup>[11]</sup>被引入，用于复用在其他环境中基于大量标注样本训练得到的DL模型，并结合新环境中的少量标注样本实现模型迁移<sup>[12-13]</sup>。面向室内指纹定位的小样本迁移学习系统，能够通过学习源环境中指纹与位置间的非线性关系，实现对新环境的快速适应，从而降低时间与人工成本<sup>[14]</sup>。然而，现有的TL定位算法存在以下两方面不足：一是，传统指纹定位需要获取大量训练数据集以区分较少的类别，才能达到较好的定位性能；二是，在设计面向室内定位的迁移学习方案时，现

有方法大多局限于参数冻结与微调策略，缺乏更高效、更灵活的迁移机制。

为解决上述问题，本文提出了一种基于孪生图卷积网络（Siamese GCN, siamese graph convolutional network）的少样本迁移学习室内指纹定位系统。本文的主要贡献如下。

1) 提出了一种基于Siamese GCN的室内指纹定位方法，将多天线的CSI特征映射为图网络，并结合GCN模型<sup>[15-16]</sup>进行图分类。同时，引入图注意力机制<sup>[17]</sup>，以提取CSI数据的空间与频率特征。实验结果表明，在两个真实场景中，该方法在定位精度与鲁棒性方面均优于现有模型。

2) 引入了基于特征嵌入的对比损失（CL, contrastive loss）函数<sup>[18]</sup>，该损失函数特别适用于类别数量较多且每类样本数量较少的数据集。有了对比损失函数的约束，模型能够在样本有限的情况下，保持同类样本特征距离紧凑、异类样本特征距离可分，从而获得更优的迁移性能。

3) 提出了一种基于最大均值差异（MMD, maximum mean discrepancy）<sup>[19]</sup>的通用领域自适应方法。该方法基于Siamese GCN模型设计新的神经网络结构与损失函数，并将已训练模型权重从其他环境迁移至任意新环境，从而显著降低数据采集与标注成本。该方法不受源域与目标域间空间规模或位置指纹数量差异的限制。

## 1 室内定位相关工作

近年来，室内定位系统一直是研究的热点领域。为简明起见，本节将综述基于人工特征的室内定位、基于DL的室内定位以及基于特征的迁移学习3方面的相关研究工作。

### 1.1 基于人工特征的室内定位

面对不同的应用场景，室内定位系统在成本与精度方面的需求各不相同<sup>[20]</sup>。在机场或购物中心等场景中，粗略的位置信息估计已能满足需求<sup>[21-22]</sup>，无须采用昂贵的高精度定位系统。因此，Wi-Fi指纹技术凭借其低成本、完善的基础设施以及良好的隐私保护性能，足以满足大多数应用需求。Wi-Fi

网络使得相关的室内定位技术在公共安全、商业、医疗等领域得到了广泛应用<sup>[5,23]</sup>。

在基于人工特征的室内定位系统中，可以根据在不同位置采集的信号数据之间的对应关系构建独特的指纹数据库。此时，系统需要将测试信号数据与指纹数据库中的样本进行匹配，并选择最相似信号对应的位置作为定位结果。Radar系统是第一个基于Wi-Fi-RSSI数据的室内指纹定位系统，证明了利用Wi-Fi指纹进行定位的可行性<sup>[24]</sup>。吴泽泰等<sup>[25]</sup>将聚类算法与k邻近算法(kNN, k-nearest neighbor)相结合，提出了一种新的Wi-Fi定位算法，在与kNN精度保持一致的基础上极大地降低了kNN的计算复杂度。此外，Youssef等<sup>[26]</sup>设计了基于高斯回归的Horus系统，用于预测位置，以提高定位精度。然而，由于信号波动和噪声干扰，基于RSSI的Horus系统性能提升仍然有限。因此，为保证较高的定位精度，指纹定位系统通常需要人工在前期采集CSI或RSSI数据。为减轻数据采集负担，Wang<sup>[27]</sup>提出了一个两层深度高斯过程(DGP, deep gaussian process)模型，以构建RSS无线电图谱。实验结果表明，即使仅使用50%的样本，定位误差变化仍不显著。

由于多径衰落和随机噪声干扰，RSSI在同一位置会出现较大波动<sup>[28]</sup>，因此仅能反映粗粒度的信道特征。相比之下，CSI能够获取正交频分复用(OFDM, orthogonal frequency division multiplexing)系统中所有子载波在频域上的响应特性，属于细粒度的信道信息。为此，研究者开始探索利用OFDM系统中的CSI数据构建鲁棒性更高、效率更高的基于Wi-Fi的指纹数据库，相关研究已证明该方法可以显著提升室内定位系统的精度<sup>[29-30]</sup>。细粒度室内指纹定位系统(FIFS, fine-grained indoor fingerprinting system)是首个利用CSI幅度信息进行定位的系统<sup>[31]</sup>。文献[32]提出的LiFS系统发现，CSI数据中的部分子载波受多径效应影响较小，并通过建立多条CSI数据链的功率衰减模型，有效提升了定位精度。针对LiFS系统的相关实验证明了CSI数据中的不同子载波具有差异化特征，这一特性为进一步优化定位性能提供了可能。

## 1.2 基于深度学习的室内定位

近年来，随着大数据技术的兴起，DL在计算机视觉与自然语言处理等多个领域取得了前所未有

的成功<sup>[33-34]</sup>。为了充分发挥DL模型在特征提取与识别方面的优势，不少研究开始尝试利用深度自编码器(DAE, deep autoencoder)进行室内定位。DeepFi系统<sup>[35]</sup>率先提出使用DAE提取CSI幅度特征，并取得了良好的定位效果。与DeepFi类似，PhaseFi<sup>[36]</sup>使用DAE对CSI的相位特征进行高效提取。在文献[37-38]中，研究者发现DNN能够在无须额外硬件部署的情况下实现更高效的室内定位。DeepFi系统最早提出在室内定位中使用深度卷积神经网络(CNN, convolutional neural network)<sup>[39]</sup>，是该领域的重要探索。与DeepFi系统为每个位置单独训练权重不同，CiFi模型采用为所有训练位置仅训练一组通用权重的策略，提升了模型效率。此外，DL方法也被用于减少数据采集过程中的人工干预。Zhang等<sup>[40-41]</sup>先后提出了基于动态自适应对抗网络的鲁棒室内定位方法，和利用图表示学习增强指纹定位稳健性的方法，实现了自动无线电地图的自适应，提高了定位精度。文献[42]研究表明，DL模型同样能够提升基于蜂窝通信的室外定位系统性能。近年来，图神经网络(GNN, graph neural network)凭借其优异的特征表示能力，已经被应用于基于DL的室内定位中，并展现出了优异的准确率和鲁棒性<sup>[43-44]</sup>。

## 1.3 基于特征的迁移学习

基于特征的TL是一种常用的方法，用于解决监督学习中训练数据不足的问题。该方法能够将不同但相关领域中的知识迁移至目标领域，从而显著减少训练时间。Pan等<sup>[45]</sup>提出了迁移主成分分析(TCA, transfer principal component analysis)算法，该算法将传统主成分分析(principal component analysis, PCA)与MMD相结合，实现了共享特征提取与跨域知识迁移。为了进一步提升TCA的性能，Long等<sup>[46]</sup>在无标注数据场景下设计了联合分布自适应(JDA, joint distribution adaptation)算法。该算法利用MMD减少不同领域间的分布差异，并结合传统PCA降维，从而实现了高效的跨域知识迁移。

此外，基于特征的迁移学习方法在室内指纹定位中同样展现其优势。小样本TL系统能够通过学习其他环境中指纹与位置之间的非线性关系，快速适应新环境，从而降低时间与人工成本。Liu等<sup>[47]</sup>提出了一种基于迁移学习的室内定位系统，该系统基于

度量学习的思想，通过学习基于距离的源域与目标域的特征嵌入，实现目标域的高效迁移。Wang等<sup>[48]</sup>提出了领域自适应网络（DAN, domain adaptive network）模型，用于高效地学习不同领域之间的知识。该模型通过对齐不同领域间的隐层均值MMD来最小化领域损失，从而实现更优的迁移效果。

## 2 预备知识与问题建模

### 2.1 CSI和信号模型

在OFDM系统中，可用的频谱带宽被划分为多个正交子载波，使信号能够在不同频率上传输而互不干扰。因此，通过提取不同频段的CSI数据，系统能够获取更丰富的无线信道特征信息，并用于评估通信链路的信道质量<sup>[49]</sup>。此外，在MIMO OFDM系统中，假定发送端和接收端分别配备了 $N_t$ 根与 $N_r$ 根天线，每个Wi-Fi数据包包含 $n_{\text{sub}}$ 个子载波，由此可以构建出复数值的CSI矩阵：

$$\mathbf{C}_{N_t, N_r} = \begin{pmatrix} H_{1,1,1} & \cdots & H_{1,N_r,n_{\text{sub}}} \\ \vdots & \ddots & \vdots \\ H_{N_t,1,1} & \cdots & H_{N_t,N_r,n_{\text{sub}}} \end{pmatrix} \quad (1)$$

矩阵中每个元素 $H_{i,j,k}$ 表示第 $i$ 根发射天线和第 $j$ 根接收天线在第 $n_{\text{sub}}$ 个子载波上的信道增益。高通Atheros网卡配备有3根天线，每根天线包含56个子载波。图1展示了在发送端天线数 $N_t$ 为1、接收端天线数 $N_r$ 为3的情况下，每个接收天线在多个连续CSI数据包中的56个子载波的信道频率响应（CFR, channel frequency response）。




图1 给定位置处多个连续CSI数据包的信道频率响应

对于每个子载波，其复数值CSI可表示为：

$$H_i = |H_i| \exp(j\angle H_i) \quad (2)$$

其中， $\angle H_i$ 表示相位， $|H_i|$ 表示幅度。

此外，幅度特征可以直接使用，而相位特征则需要先转换为相位差，并通过如下表达式进一步转化为到达角（AOA, angle of arrival）信息：

$$\theta_i = \arccos(\Delta\angle\hat{H}_i \lambda / 2\pi d) \quad (3)$$

其中， $\Delta\angle\hat{H}_i$ 表示相邻两根天线的相位差， $\theta_i$ 表示计算得到的AOA值， $\lambda$ 和 $d$ 分别表示波长和相邻天线间隔。

### 2.2 基于CSI的室内定位

假设射频指纹 $x$ 与位置 $l$ 是服从联合分布 $p(x, l)$ 的随机变量。 $x$ 与 $l$ 的取值空间分别称为 $m$ 维指纹空间与二维位置空间，对应于统计学习框架下的输入空间与输出空间。指纹空间与位置空间共同构成样本空间 $\mathcal{X} \times L$ 。假设在样本空间中，对于任意样本 $(x, l) \in \mathcal{X} \times L$ ，都存在一个真实但未知的位置映射函数：

$$L = f(\mathcal{X}) \quad (4)$$

对应于位置指纹判定模型。射频指纹定位的目标是对该位置判定函数进行估计。基于CSI的室内指纹定位模型可以视为一种分类模型，因此，所有基于DL的分类模型都可用于求解该位置判定函数。室内指纹定位系统设计如图2所示。室内指纹定位过程可以分为两个阶段：离线阶段与在线阶段。

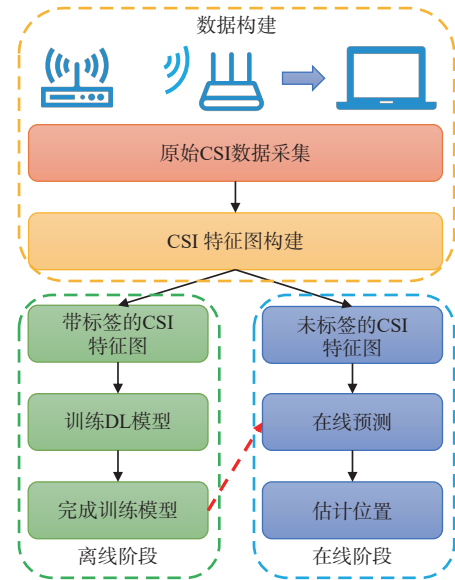


图2 室内指纹定位系统设计

1) 离线阶段：该阶段也称为指纹采集与训练阶段。首先，利用路由器在位置空间中采集原始CSI数据，并将其对应的坐标作为标签。随后，将原始CSI数据预处理为CSI特征图，以便神经网络

进行特征提取。进一步地，将带标签的 CSI 特征图输入 DL 模型进行训练，使神经网络能够充分学习信号特征与其实际位置之间的非线性关系。

2) 在线阶段：该阶段以未标注的 CSI 特征图作为输入，利用训练好的 DL 模型权重得到最终的预测坐标。

室内指纹定位系统的主要目标是，使在离线阶段学习到的位置判定函数能够推广到在线阶段的样本。这也是几乎所有监督机器学习需要解决的核心问题。

### 2.3 孪生网络

在本小节中，将简要介绍所提出室内定位系统中使用的孪生网络，其原理如图 3 所示。目前，孪生网络在计算机视觉领域已表现出了优异的性能<sup>[50-52]</sup>。从图 3 可以看到，孪生网络由两个分支组成，且它们的输入不同，例如两幅不同的图像，分别记为  $X_1$  和  $X_2$ 。这两个输入分别通过 DL 模型提取其隐含特征，且两个 DL 模型的参数是共享的。因此，可以认为对  $X_1$  和  $X_2$  进行了相同的变换函数  $\phi(\cdot)$ ，其特征嵌入分别表示为  $\phi(X_1)$  和  $\phi(X_2)$ 。进一步地，通过合适的相似度计算函数  $d(\cdot)$  来度量两组特征嵌入之间的相似性。对于孪生网络，其相似度函数  $D(\cdot)$  可表示为：

$$D_{\text{similarity}}(X_1, X_2) = d(\phi(X_1), \phi(X_2)) \quad (5)$$

其中， $D_{\text{similarity}}(X_1, X_2)$  的取值表示孪生网络在输入  $X_1$  和  $X_2$  时输出的相似度分数，通常采用欧氏距离来表示。

### 2.4 基于迁移学习的室内定位

TL 的目的在于利用源域与目标域数据之间的共性，学习目标域的判定函数。TL 在室内定位中的基本假设是：离线阶段与在线阶段的数据分布来自两个不同但相关的域。该域可以由一个特征空间




图 3 孪生网络原理

和一个边缘分布来定义。源域中的指纹记为  $D_s$ ，表示离线阶段的指纹采集域。在给定域的情况下，可以将该域中的任务定义为由标签空间和判定函数组成，记为  $T_s$ 。进一步地，目标域  $D_T$  及目标域中的任务  $T_T$  也可以定义出来，它们分别表示在线阶段的指纹获取域与域任务。

基于 TL 的室内指纹定位系统面临若干挑战：①构建指纹数据库需要收集大量标注数据，这一过程既耗时又昂贵。②指纹数据库与采集环境密切相关，每进入一个新环境就需要重新采集独立的新指纹数据。③即使在同一环境中采集到位置指纹，指纹特征也会随时间发生变化，因此需要持续更新。

为了解决上述挑战，本文提出了一种小样本 TL 技术。该技术能够在不同室内环境下显著降低数据标注与指纹构建的成本。具体而言，通过复用在其他环境中利用大量标注样本训练好的 DL 模型，并结合在新环境中采集的少量标注样本，实现高精度的定位。

## 3 基于 Siamese GCN 的室内指纹定位方法

基于 Siamese GCN 的室内指纹定位系统架构如图 4 所示。该系统包括以下 4 个部分：CSI 特征图构建、特征嵌入、分类识别与位置预测。

### 3.1 CSI 特征图构建

为提高定位准确性，利用原始数据的幅度与相

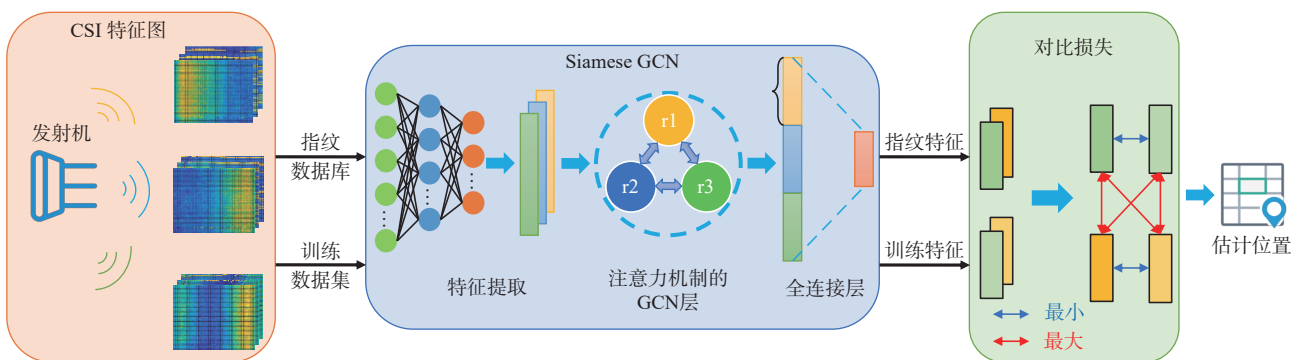


图 4 基于 Siamese GCN 的室内指纹定位系统架构

位构建 CSI 特征图，以便进行特征提取。本文所用的 Qualcomm 网卡配备有 3 根天线，包含 56 个子载波，每个子载波的 CSI 是一个包含幅度与相位偏移的复数值。考虑到接收端包含 3 根天线，而每根天线包含 56 个子载波，因此在每个位置需要选择 56 个 CSI 数据包，以形成一个 CSI 特征图，其尺寸为  $56 \times 56 \times 3$ ，分别对应 CSI 数据包数量、子载波数量与接收端天线数量。进一步地，由于发送端同样包含 3 根天线，来自发送端某一固定位置天线的信号即可构建一个 CSI 特征图，因此 3 根发送天线可被视为 3 个 CSI 特征图  $I = I_1, I_2, I_3$ 。

### 3.2 基于 Siamese GCN 的特征嵌入

采用基于 GCN 的特征嵌入方法，将原始 CSI 样本映射为特征。这里，基于 Siamese GCN 的特征嵌入主要包括 3 个部分：特征提取、GCN 层与全连接（FC, fully connected）层。

1) 特征提取：经 CNN 提取高维特征后，可以将  $I$  降维为一维向量。特征提取网络由 4 个卷积层和 1 个最大池化层组成，每个卷积层后均加入修正线性单元（ReLU, rectified linear unit）作为激活函数。此外，考虑到 CSI 特征的空间分辨率，最大池化层仅在前 2 个卷积层之后使用。由于 CSI 特征图的输入维度较真实图像像素小，因此未采用批量归一化（BN, batch normalization）层与 Dropout 层。在充分提取 CSI 特征图的隐含特征后，通过一个包含 2 048 个神经元的 FC 层，将 CSI 特征映射为一维向量。由此，3 根发送天线可以生成 3 个 CSI 特征向量。

2) GCN 层：定义一个三角图  $G = (V, E)$ ，其中包含 3 个节点  $V = \{v_1, v_2, v_3\}$  和 3 条边  $E = \{e_{12}, e_{23}, e_{31}\}$ 。具体而言，将提取到的 3 根天线分别对应的 CSI 特征嵌入映射为图  $G$  的 3 个节点，其中节点  $v_i$  表示第  $i$  根天线提取的 CSI 特征向量，边  $e_{ij}$  则表示天线  $i$  与  $j$  之间的特征相似度。考虑到 3 根天线间的信号存在近场耦合与共同路径传播，全连接拓扑可确保 GCN 在卷积时聚合所有天线之间的信息，实现对全局空间特征的联合建模，从而可以采用 GCN 领域的分类模型来识别 CSI 位置指纹。为了实现 CSI 位置指纹的识别，采用了两层 GCN。不同 GCN 层中的节点按照如下方式进行信息传递：

$$h_n^{k+1} = \rho \left( \sum_{m \in N_n} h_m^k w^k \right) \quad (6)$$

其中， $h_n^{k+1}$  表示第  $n$  个节点在第  $k+1$  层的特征向量， $N_n$  表示第  $n$  个节点的邻居节点集合， $h_m^k$  表示第  $m$  个节点在第  $k$  层的特征向量， $w^k$  为连接第  $n$  个节点与其邻居的权重参数， $\rho(\cdot)$  为激活函数。

在图卷积过程中，每个节点会向其邻居传递消息，也会融合从邻居节点接收到的消息。为了对输入数据进行归一化处理，在每一层之后加入了 BN 层。

此外，当 GCN 在相邻节点之间传递消息时，Siamese GCN 默认是对相邻节点的信息权重进行平均处理。然而，不同相邻节点对当前节点的重要性可能存在差异。因此，在 GCN 网络中引入了图注意力机制，使相邻节点信息的聚合方式由加权平均实现。这意味着在 GCN 网络中，不同发送天线对最终位置估计的贡献程度并不相同。相邻节点的权重计算方式如下：

$$e_{ij} = \alpha \left( W \vec{h}_i, W \vec{h}_j \right) \quad (7)$$

其中， $\alpha$  表示注意力机制， $W$  和  $\vec{h}$  分别是权重参数和节点特征向量的拼接。

为了使各个顶点上的系数具有可比性，采用 Softmax 对所有  $j$  进行归一化处理：

$$\alpha_{ij} = \text{Softmax}_j(e_{ij}) = \frac{\exp e_{ij}}{\sum_{k \in N_i} \exp e_{ik}} \quad (8)$$

将式(7)代入式(8)， $\alpha_{ij}$  可表示为：

$$\alpha_{ij} = \frac{\exp \left( \text{LeakyReLU} \left( \alpha \left( W \vec{h}_i, W \vec{h}_j \right) \right) \right)}{\sum_{k \in N_i} \exp \left( \text{LeakyReLU} \left( \alpha \left( W \vec{h}_i, W \vec{h}_k \right) \right) \right)} \quad (9)$$

通过上述设计，可以在训练过程中同时优化节点特征表示与边权分布，实现对不同天线的特征相似度的建模，进而提升模型在不同环境下的泛化能力。

3) FC 层：基于对 CSI 数据空间特征与频率特征的提取，借助 3 层 FC 层网络获得最终的特征嵌入。

Siamese GCN 模型的网络层结构与维度配置见表 1。通过 Siamese GCN 获取特征嵌入的过程如算法 1 所示。

**算法 1** 基于 Siamese GCN 的特征嵌入算法

**输入** 射频指纹数据集  $D_a$

**输出**  $f_{FE}(W_{FE}), f_G(W_G), f_{FC}(W_{FC})$

1. 构建特征嵌入的特征提取层、GCN层和FC层
2. 加入对比损失  $L_{\text{contrastive}}$ ;
3. 设置超参数:
  - 设置学习率  $\alpha$ ;
  - 设置最大训练次数  $T$ ;
4. 在数据集  $\mathbf{D}_a = \{x_a, l_a\}_{a=1}^N$  上训练:
5. **For**  $t = 1$  to  $T$  **do**
6.     前向传播:
  7.              $r_a = f_{\text{FE}}(W_{\text{FE}}; x_a)$ ;
  8.              $g_a = f_{\text{G}}(W_{\text{G}}; r_a)$ ;
  9.              $z_a = f_{\text{FC}}(W_{\text{FC}}; g_a)$ ;
10.     反向传播:
11.     更新特征提取层权重 ( $W_{\text{FE}}$ );
12.     更新GCN层权重 ( $W_{\text{G}}$ );
13.     更新FC层权重 ( $W_{\text{FC}}$ );
14. **end for**
15. 返回  $f_{\text{FE}}(W_{\text{FE}}), f_{\text{G}}(W_{\text{G}}), f_{\text{FC}}(W_{\text{FC}})$

表1 Siamese GCN 模型网络层结构与维度配置

网络层结构	维度
Conv2D + ReLU	256 × (3 × 3)
Conv2D + ReLU	256 × (2 × 2)
最大池化层(max pooling)	(2 × 2)
Conv2D + ReLU	256 × (3 × 3)
Conv2D + ReLU	256 × (2 × 2)
最大池化层	(2 × 2)
扁平化(Flatten)	2 048
GCN层 + ReLU	(2 048, 1 024)
GCN层 + ReLU	(1 024, 512)
拼接(Concat)	(512, 1 536)
FC层	(1 536, 512)
FC层	(512, 128)
FC层	(128, 16)

### 3.3 基于Siamese网络的判别特征嵌入

多数传统的指纹定位方法需要获取大量训练数据集，并且仅需区分少量类别。在这种情况下，基于Softmax损失训练的DL模型通常能够取得较好性能。然而，基于CSI指纹的室内定位模型可以视为一个包含大量位置类别的分类模型。在此情形下，采用Softmax损失训练往往在泛化性与判别性方面表现不足。为此，本文引入孪生网络来应对这一挑战，其采用CL损失函数，非常适用于类别数量众多而每个类别样本相对较少的场景。

Siamese GCN 系统将数据集划分为数据库样本与训练样本，其中数据库样本在每个位置单独采集。两类样本  $X_1$  和  $X_2$  被输入基于 Siamese GCN 的特征嵌入，从而促使相近位置的样本在特征空间中的距离收缩，而相隔较远位置的样本在特征空间中的距离拉大，判别特征嵌入示意图如图 5 所示。此外，特征空间中的距离通常采用欧氏距离进行度量。根据式(5)，特征距离（相似度） $D_{\text{similarity}}$  与对比损失  $L_{\text{contrastive}}$  可表示为：

$$D_{\text{similarity}}(X_1, X_2) = \|\phi(X_1) - \phi(X_2)\|_2 = \left[ \sum_{i=1}^p (\phi(X_1^i) - \phi(X_2^i))^2 \right]^{\frac{1}{2}} \quad (10)$$

$$L_{\text{contrastive}} = \frac{1}{2N} \sum_{n=1}^N [Y D_{\text{similarity}}^2 + (1 - Y) \max(\text{margin} - D_{\text{similarity}}, 0)^2] \quad (11)$$

其中， $Y$  表示两组输入是否相似的标签， $N$  为同一训练批次中的样本数量， $\text{margin}$  为需要设定的阈值。当  $Y = 1$ （样本相似）时，对比损失为：

$$\frac{1}{2N} \sum_{n=1}^N D_{\text{similarity}}^2 \quad (12)$$

对于相似样本，需要减小其特征距离，以获得更优的损失值。当  $Y = 0$ （即样本不相似）时，对比损失函数为：

$$\frac{1}{2N} \sum_{n=1}^N \max(\text{margin} - D_{\text{similarity}}, 0)^2 \quad (13)$$

此时需要增大  $D_n$ ，从而获得更小的对比损失值。




图5 判别特征嵌入示意图

### 3.4 位置估计

在完成CSI特征图训练后，Siamese GCN系统能够识别出在指纹数据库中与当前位置最接近的坐标。为了获得更精确的位置，不能直接将欧氏距离最近的坐标作为预测位置，否则会导致定位结果离散化并产生较大误差。因此，选取数据库与测试特

征嵌入之间欧氏距离最近的前  $k$  个坐标，并对其进行加权平均，作为最终的预测结果：

$$(\hat{x}, \hat{y}) = \frac{\sum_{i=1}^k \frac{1}{l_i} (x_i, y_i)}{\sum_{i=1}^k \frac{1}{l_i}} \quad (14)$$

其中， $l_i$  表示第  $k$  个特征嵌入的欧氏距离； $k$  的取值应通过实验进行最优选择。

预测位置的整体流程如算法2所示。

**算法2** 基于CSI位置图像的位置估计算法

输入 CSI 特征图像  $x = \{x_1, x_2, x_3\}$ ；训练特征提取网络  $\phi$ ；图  $G = (V, E)$  和图的训练权重  $W_G$

输出 在线预测坐标  $P_{\text{pre}}$

1. 利用  $x$  作为网络的输入来提取高维特征  $r = \phi(x) = \{r_1, r_2, r_3\}$ ；

2. 使用提取的特征  $r$  作为图的3个节点，采用全连接拓扑有效地聚合相邻特征  $g = G(r) = \{g_1, g_2, g_3\}$ ；

3. 使用 FC 层来获得最终的特征嵌入： $z = f_{\text{FC}}\{\text{concat}(g_1|g_2|g_3)\}$ ；

4. 获取数据库与测试特征嵌入之间欧氏距离最近的前  $k$  个坐标： $l_k = \|z_k - d_k\|_2$ ；

5. 对前  $k$  个坐标  $P = \{p_1, p_2, \dots, p_k\}$  和  $l_i = \{l_1, l_2, \dots, l_k\}$  进行加权平均，所得值作为最终的预测结果：

$$P_{\text{pre}} = \frac{\sum \frac{1}{l_k} p_k}{\sum \frac{1}{l_k}};$$

6. 返回  $P_{\text{pre}}$ 。

**4 基于 Siamese GCN 的小样本迁移学习方案**

本节设计了一种基于 Siamese GCN 的小样本 TL 方案，用于室内定位。具体而言，提出了一种以最

小化源域与目标域之间的 MMD 为核心的迁移学习方法。在此基础上，利用已训练模型的权重及新环境中少量的 CSI 数据，进一步设计了新的神经网络结构与损失函数，以实现精确的定位性能。

射频指纹迁移学习场景通常可分为时间迁移、设备迁移与场景迁移3类。本文主要解决不同室内环境下数据采集与维护成本较高的问题，属于场景迁移范畴。通常情况下，若已在其他环境中训练得到一个 Siamese GCN 模型，而在新环境中仅有少量 CSI 样本可用，常采用参数冻结与微调 (fine-tuning) 策略。然而，在本文所提出的基于特征的迁移学习方案中，还可以通过最小化源域与目标域之间的 MMD 来学习跨域迁移成分。由于特征提取部分的图卷积层主要负责对原始 CSI 数据进行降维与特征提取，因此仅在最后的 FC 层中引入基于 MMD 的领域自适应机制。基于 Siamese GCN 的小样本迁移学习系统如图6所示。随着神经网络结构的加深，来自不同域的特征差异逐渐显现，该机制有助于增强模型在新环境中的泛化能力。

**4.1 最大均值差异**

MMD 是一种用于衡量两个分布在再生希尔伯特空间 (RKHS, reproducing kernel Hilbert space) 中距离的度量方法，也是 TL 系统中最常用的指标之一。根据前述内容，仅在最后一个 FC 层中选择一层应用基于 MMD 的领域自适应机制。经过该全连接层后，源域与目标域的输出分别为  $f(d_s)$  和  $f(d_t)$ ，二者之间的 MMD 损失可表示为：

$$L_{\text{MMD}}(\mathbf{D}_S, \mathbf{D}_T) = \left\| \frac{1}{|\mathbf{D}_S|} \sum_{d_s \in \mathbf{D}_S} f(d_s) - \frac{1}{|\mathbf{D}_T|} \sum_{d_t \in \mathbf{D}_T} f(d_t) \right\|_H^2 \quad (15)$$

因此，可以将模型的损失函数转换为两个损失项的加权和形式：

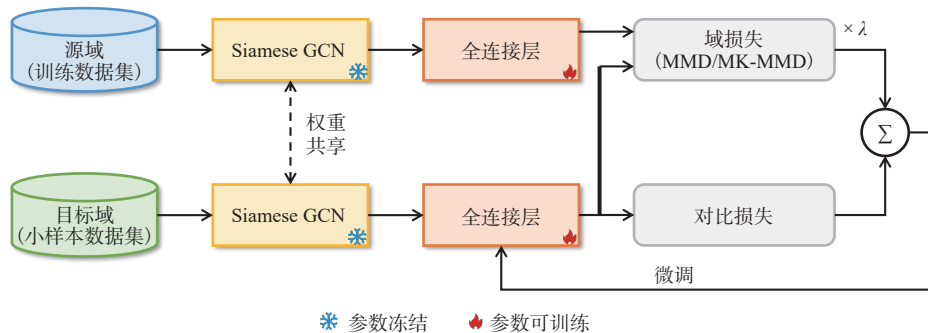


图6 基于 Siamese GCN 的小样本迁移学习系统

$$L = L_{\text{contrastive}}(\mathbf{D}_T) + \eta L_{\text{MMD}}(\mathbf{D}_S, \mathbf{D}_T) \quad (16)$$

其中,  $\eta$  为对比损失与MMD损失之间的平衡系数。

#### 4.2 多核最大均值差异

基于多核最大均值差异 (MK-MMD, multiple kernel maximum mean discrepancy) 的领域自适应是MMD的改进版本, 可对多个FC层进行联合自适应, 从而获得更优的迁移性能。与传统的单核MMD不同, MK-MMD将原先的单一核函数替换为多个核函数, 其表达式如下:

$$K^\Delta = \left\{ k = \sum_{u=1}^m \beta_u k_u; \beta_u \geq 0, \forall u \right\} \quad (17)$$

其中,  $K$  表示核函数, 通过对  $m$  个不同的核函数进行加权以实现多核效果, 其中  $k_u$  和  $\beta_u$  分别表示第  $u$  个核函数及其加权系数。

基于MK-MMD的领域自适应可同时作用于所有FC层, 其表达式为:

$$L_{\text{MK-MMD}}(\mathbf{D}_S, \mathbf{D}_T) = \sum_{l=1}^{l_h} d_K^2(\mathbf{D}_S^l, \mathbf{D}_T^l) = \sum_{l=1}^{l_h} \left\| \frac{1}{|\mathbf{D}_S^l|} \sum_{d_s \in \mathbf{D}_S^l} f(d_s) - \frac{1}{|\mathbf{D}_T^l|} \sum_{d_t \in \mathbf{D}_T^l} f(d_t) \right\|_H^2 \quad (18)$$

其中,  $l$  表示当前所作用的FC层。此时, 模型的加权损失函数可表示为:

$$L = L_{\text{contrastive}}(\mathbf{D}_T) + \eta L_{\text{MK-MMD}}(\mathbf{D}_S, \mathbf{D}_T) \quad (19)$$

### 5 实验与评估

#### 5.1 数据采集和实验设置

实验采用两台搭载 Atheros 网卡的 TP-Link 4310 路由器分别作为发射端和接收端。原始CSI数据通过改进后的网卡驱动程序, 并使用 AtherosC-SITool 进行接收。为了接收5G频段信号, 子载波数设定为56, 信号频率为5.180 GHz。发射端与接收端均配备3根天线, 因此在每个测量点处接收到的单个CSI数据包格式为  $3 \times 3 \times 56$ 。

在南京创智大厦7楼的两个典型室内环境中对本文所提系统的性能进行了评估。两个环境均使用固定位置的发射端与接收端 (发射端用红色标记, 接收端用蓝色标记)。两个代表性室内环境的布局如图7所示, 其中图7(a)的实验室 (Laboratory) 为一个开放式会议室, 包含43个测点 (以红色实心圆标记); 图7(b)的走廊 (Corridor) 包含66个测点 (同样以红色实心圆标记)。在每个测

点, 采集了超过1000个CSI数据包。根据前述CSI特征图构建方法, 每56个CSI数据包被视为一个CSI样本。每个位置共包含15个样本, 其中2个用于构建指纹数据库, 10个用于训练集, 3个用于测试集。




图7 两个代表性室内环境的布局

进一步地, 实验室与走廊在布局、空间尺寸及测点数量等方面完全不同, 非常适合用于验证迁移学习系统的有效性。将实验室定义为源域, 将走廊定义为目标域, 并在走廊中每个位置选取少量样本, 以构建迁移训练数据集。本文中考虑  $n \in 1, 2, 3$ , 在小样本学习框架下分别比较了1-shot、2-shot和3-shot三种方案的性能。

仿真实验在 Ubuntu 16.04.7 操作系统上进行, 采用 NVIDIA Tesla V100 GPU, 用于大规模数据矩阵的计算。原始CSI指纹数据的预处理在 MATLAB R2021a 软件中完成。此外, 利用深度学习库 Pytorch 1.10 对所提出的 Siamese GCN 系统进行训练。仿真实验的主要参数设置见表2。

表2 仿真实验的主要参数设置

实验参数	取值
样本维度 $x$	$56 \times 56 \times 3$
每类样本数量	15
训练集与验证集比例	8:2
激活函数	Sigmoid
特征嵌入维度	16
批量大小 $T$	32
最大迭代轮数	100
学习率 $\alpha$	0.001
平衡因子 $\lambda$	0.25

### 5.2 不同深度学习算法下的室内定位性能

在两种不同的环境下，将 Siamese GCN 的定位性能与其他 4 种 DL 模型进行比较，它们分别是 Res-Loc<sup>[9]</sup>、SCNN-CSI<sup>[18]</sup>、CiFi<sup>[39]</sup>和 DEEPFi<sup>[53]</sup>。为了更直观地体现 Siamese GCN 模型在定位精度方面的优势，还比较了采用传统 Softmax 损失的 GCN 模型的定位准确率。具体的定位误差结果见表 3。各模型在实验室环境下的定位误差累积分布函数 (CDF, cumulative distribution function) 如图 8 所示。从图 8 可以看出，Siamese GCN 模型与 GCN 模型的平均定位误差分别为 1.322 5 m 和 1.428 5 m，均低于 SCNN-CSI 模型 (1.513 3 m) 与 Res-Loc 模型 (1.844 8 m)。此外，Siamese GCN 模型与 GCN 模型在 80% 分位点处的定位误差分别为 2.012 3 m 与 2.043 8 m，分别比 SCNN-CSI 模型低 0.2 m 和 0.1 m。与 GCN 模型相比，Siamese GCN 模型表现出更优的定位效果，说明在类别数量较多的情况下，CL 相比于 Softmax 损失具有更强的分类判别能力。进一步地，从 CDF 曲线可见，SCNN-CSI 模型与 GCN 模型在前 40% 区间内的平均误差相近，但从 50% 起，GCN 的误差明显低于 SCNN-CSI 模型，且表现得更为稳定。

表 3 定位误差

环境	模型	平均误差/m	80% 分位点处的分位误差/m
实验室	Siamese GCN	1.322 5	2.012 3
	GCN	1.428 5	2.043 8
	SCNN-CSI <sup>[18]</sup>	1.513 3	2.249 1
	Res-Loc <sup>[9]</sup>	1.844 8	2.380 1
	CiFi <sup>[39]</sup>	2.154 7	2.941 2
	DeepFi <sup>[53]</sup>	2.456 8	3.847 9
	走廊	Siamese GCN	2.133 7
GCN		2.244 8	3.322 1
SCNN-CSI <sup>[18]</sup>		2.453 5	3.724 5
Res-Loc <sup>[9]</sup>		2.857 1	4.176 4
CiFi <sup>[39]</sup>		3.117 1	4.853 7
DeepFi <sup>[53]</sup>		3.514 1	5.734 1

各模型在走廊环境下的定位误差 CDF 如图 9 所示。由于走廊环境中存在更多非视距 (NLoS, non-line-of-sight) 条件，如墙体空间阻隔，信号更易产生衰落，导致定位误差增加。在这种情况下，Siamese GCN 模型的平均定位误差与 80% 分位误差

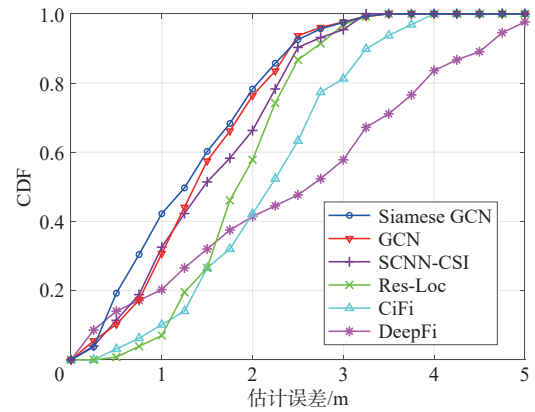


图 8 各模型在实验室环境下的定位误差 CDF

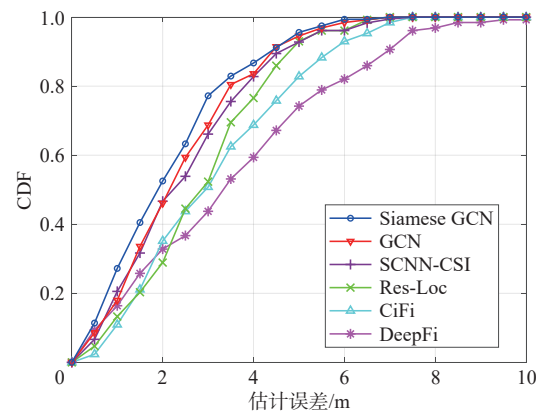


图 9 各模型在走廊环境下的定位误差 CDF

分别为 2.133 7 m 和 3.213 8 m，仍然低于其他 DL 模型。值得注意的是，SCNN-CSI 模型同样采用了孪生网络结构，但无论在何种环境下，其定位误差均高于 Siamese GCN 模型。与纯 CNN 模型相比，本文提出的图网络能够更有效地提取 CSI 数据的空间与频率特征，而引入的图注意力机制进一步提升了定位精度。综上所述，Siamese GCN 模型在两个不同的实际环境中均表现出最优的定位性能。

### 5.3 不同参数的影响

1) 对比损失中 margin 参数的影响。在两个不同环境下，margin 取值从 1.0 到 11.0 时的平均定位误差 (MEE, mean estimated error) 变化如图 10 所示。由图 10 可知，当 margin = 5.0 时，MEE 最小，定位性能最佳。不论 margin 值大于还是小于该数值，定位性能均会下降。因此，在后续所有基于 Siamese GCN 的定位模型中，均将 margin 设定为 5.0。

2) k 的影响分析。由上述结果可知，参数 k 对定位性能具有重要影响。不同 k 值下 Siamese GCN 模型的定位准确率如图 11 所示，随着 k 的增大，正




图10 不同margin的MEE




图12 不同k值下Siamese GCN模型的MEE




图11 不同k值下Siamese GCN模型的定位准确率

确位置落入候选坐标集合的概率逐渐提高。在走廊环境中，当  $k = 7.0$  时，候选坐标集合包含正确位置的概率接近80%；而在实验室环境中，该指标进一步提升至约90%。然而，当  $k$  继续增大时，该概率的增长趋势逐渐减缓。

不同  $k$  值下 Siamese GCN 模型的 MEE 如图 12 所示。在两种实验环境下，参数  $k$  的取值范围为 1.0~15.0。由图 12 可知，当  $k = 5.0$  时，无论是在实验室还是走廊环境下，MEE 均达到最优。随着  $k$  的增大或减小，预测误差均呈现出上升趋势。此外，当  $k$  进一步增大时，平均定位误差的变化不再显著。综合分析 Siamese GCN 模型在两个实验环境下的定位性能，最终选择  $k = 5.0$  作为最优参数。

#### 5.4 基于 Siamese GCN 与 GCN 模型的迁移学习系统定位性能对比

基于 TL 系统的 Siamese GCN 与 GCN 模型的平均定位误差见表 4。其中，Baseline 表示在使用完整数据集时所能达到的最佳定位性能， $n$ -shot 表示每个位置处使用的 CSI 样本数量。由表 4 可以看出，引入实验室中已训练好的模型后，定位性能得到了

表4 不同迁移学习系统的平均定位误差

模型	训练方式	定位误差/m		
		1-shot	2-shot	3-shot
Siamese GCN	TL	2.727 9	2.445 1	2.274 9
	Without TL	3.945 1	3.394 5	2.942 6
	Baseline	2.133 7		
GCN	TL	3.031 7	2.651 3	2.401 5
	Without TL	4.040 5	3.764 9	3.231 1
	Baseline	2.2448		

显著提升。这表明，Siamese GCN 模型能够通过利用其他环境中的训练样本来提高其有效性与鲁棒性。其次，随着  $n$  的增加，所有模型的性能均有所提升，但定位误差的改善呈现出边际递减效应。从 1-shot 到 2-shot 阶段，定位性能的提升速度明显快于其他阶段。这一现象可以说明：随着训练样本数量的增加，预测结果逐渐趋于稳定。最后，基于 Siamese GCN 模型的迁移学习系统在定位性能上显著优于 GCN 模型。在 3-shot 情况下，Siamese GCN 的平均定位误差为 2.274 9 m，而 GCN 模型为 2.401 5 m。性能提升的原因在于，与传统的 Softmax 损失相比，孪生网络中的 CL 能够在有限样本条件下更好地挖掘样本间的内在关联关系，从而提升模型的判别能力与泛化性能。

为更直观地理解表 4 中模型的迁移性能，还计算了各方案相对于基线 (Baseline) 定位误差的比例，其结果如图 13 所示。在 3-shot 情况下，基于 Siamese GCN 的 TL 模型达到了基线性能的 95%，而 GCN 模型仅为 85%。这一结果进一步验证了本文方法在室内指纹定位应用中的优势，即能够有效复用其他环境中已采集的数据。通过将训练好的模

型迁移至新环境，可显著降低数据采集与标注的成本。

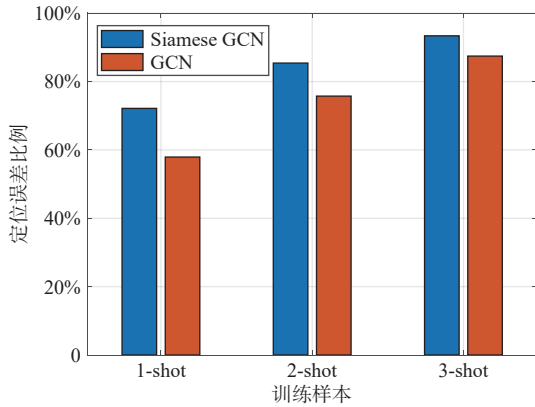


图13 不同训练样本下模型相对基线定位误差的比例

### 5.5 基于MK-MMD的迁移学习系统定位性能

为验证在MMD框架下深度领域自适应网络的迁移性能，测量并比较了基于Siamese GCN的定位系统在以下3种迁移方案下的MEE：①仅进行简单fine-tuning；②在单个FC层上应用基于MMD的领域自适应；③在多个FC层上应用基于MK-MMD的领域自适应。不同训练样本中，3种迁移方案下TL系统的MEE如图14所示。与单纯的微调方案相比，采用基于MMD的领域自适应在各个情况下均表现出更高的定位性能。这表明，引入基于MMD的正则化能够有效提升迁移性能。进一步地，对比MMD与MK-MMD两种领域自适应方案，在3-shot情况下，基于MK-MMD的方案平均定位误差仅为2.188 1 m，优于MMD的2.245 6 m。即使在样本量较少的情况下，基于MK-MMD的方案相比单纯微调平均可提升约8%，相比MMD提升约4%。这表明，基于MK-MMD的深度TL方案能够有效利用多个FC层的潜在特征信息，从而提升定位性能。

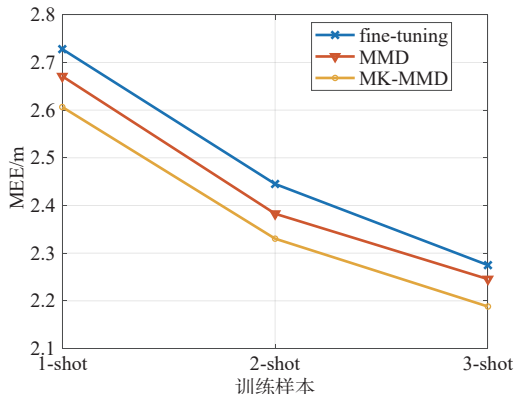


图14 3种迁移方案下TL系统的MEE

在MK-MMD框架下基于Siamese GCN的迁移学习模型的CDF曲线如图15所示。结果表明，所提出的TL系统在走廊场景中仅使用30%的标注样本即可实现最优定位性能。




图15 在MK-MMD框架下基于Siamese GCN的迁移学习模型的CDF曲线

## 6 结束语

本文提出了一种基于Siamese GCN的小样本TL系统，用于室内指纹定位。该系统通过将已训练模型的权重从其他环境迁移至仅含少量标注样本的新环境中，实现了显著降低数据采集与标注成本的目标。实验结果表明，在两种异构环境下，本文所提的迁移学习系统仅使用30%的标注样本即可获得最优的定位性能。此外，本文所提系统也为指纹定位中常见的指纹数据库采集、更新与迁移等问题提供了有效的解决路径。

需要指出的是，迁移学习的成功应用通常要求源环境与目标环境具有一定的相似性，才能有效减少训练时间和成本。如果两个场景之间差异过大，迁移学习的效果可能受限，甚至需要接近重新训练所需的数据量才能达到理想性能。此外，若直接迁移自不相关场景下训练的模型，还可能对性能产生负面影响。因此，在当前阶段，本文所提的迁移模型主要适用于场景相似的情况。进一步地，本文所提模型还需要应对同一个场景下时间推移导致的定位精度下降问题。为此，定期更新模型以适应环境变化是必要的，且需要对模型进行长期地监测和修正。因此，未来的研究方向可包括引入MAML等元学习框架<sup>[54-55]</sup>，探索模型在不同复杂任务间的动态适应机制，以进一步增强本文提出的Siamese GCN系统的实用性与可部署性。

## 参考文献:

- [1] 闫大禹, 宋伟, 王旭丹, 等. 国内室内定位技术发展现状综述[J]. 导航定位学报, 2019, 7(4): 5-12.  
YAN D Y, SONG W, WANG X D, et al. Review of development status of indoor location technology in China[J]. Journal of Navigation and Positioning, 2019, 7(4): 5-12.
- [2] ZHANG L, CHEN Z H, CUI W, et al. WiFi-based indoor robot positioning using deep fuzzy forests[J]. IEEE Internet of Things Journal, 2020, 7(11): 10773-10781.
- [3] SHAO W H, LUO H Y, ZHAO F, et al. Accurate indoor positioning using temporal-spatial constraints based on Wi-Fi fine time measurements[J]. IEEE Internet of Things Journal, 2020, 7(11): 11006-11019.
- [4] WANG Z, GUO B, YU Z W, et al. Wi-Fi CSI-based behavior recognition: from signals and actions to activities[J]. IEEE Communications Magazine, 2018, 56(5): 109-115.
- [5] 陈斌涛, 刘任任, 陈益强, 等. 动态环境中的WiFi指纹自适应室内定位方法[J]. 传感技术学报, 2015, 28(5): 729-738.  
CHEN B T, LIU R R, CHEN Y Q, et al. WiFi fingerprint based self-adaptive indoor localization in the dynamic environment[J]. Chinese Journal of Sensors and Actuators, 2015, 28(5): 729-738.
- [6] 朱正伟, 蒋威, 张贵玲, 等. 基于RSSI的室内WiFi定位算法[J]. 计算机工程与设计, 2020, 41(10): 2958-2962.  
ZHU Z W, JIANG W, ZHANG G L, et al. Indoor WiFi location algorithm based on RSSI[J]. Computer Engineering and Design, 2020, 41(10): 2958-2962.
- [7] GÖNÜLTAŞ E, LEI E, LANGERMAN J, et al. CSI-based multi-antenna and multi-point indoor positioning using probability fusion[J]. IEEE Transactions on Wireless Communications, 2022, 21(4): 2162-2176.
- [8] 宁夏薇, 夏林元, 祝宏宇, 等. 基于增强指纹特征的WiFi室内定位方法[J]. 地理空间信息, 2024, 22(8): 102-106.  
NING X W, XIA L Y, ZHU H Y, et al. WiFi indoor location method based on enhanced fingerprint feature[J]. Geospatial Information, 2024, 22(8): 102-106.
- [9] WANG X Y, WANG X Y, MAO S W. Indoor fingerprinting with bimodal CSI tensors: a deep residual sharing learning approach[J]. IEEE Internet of Things Journal, 2021, 8(6): 4498-4513.
- [10] KO C H, WU S H. A framework for proactive indoor positioning in densely deployed WiFi networks[J]. IEEE Transactions on Mobile Computing, 2022, 21(1): 1-15.
- [11] PAN S J, YANG Q. A survey on transfer learning[J]. IEEE Transactions on Knowledge and Data Engineering, 2010, 22(10): 1345-1359.
- [12] LI L, GUO X S, ZHAO M X, et al. TransLoc: a heterogeneous knowledge transfer framework for fingerprint-based indoor localization[J]. IEEE Transactions on Wireless Communications, 2021, 20(6): 3628-3642.
- [13] ZHANG Y, WU C B, CHEN Y. A low-overhead indoor positioning system using CSI fingerprint based on transfer learning[J]. IEEE Sensors Journal, 2021, 21(16): 18156-18165.
- [14] LIU K, ZHANG H, NG J K, et al. Toward low-overhead fingerprint-based indoor localization via transfer learning: design, implementation, and evaluation[J]. IEEE Transactions on Industrial Informatics, 2018, 14(3): 898-908.
- [15] SHEN W X, ZHANG H X, GUO S S, et al. Time-wise attention aided convolutional neural network for data-driven cellular traffic prediction[J]. IEEE Wireless Communications Letters, 2021, 10(8): 1747-1751.
- [16] CHIOU M J, LIU Z G, YIN Y F, et al. Zero-shot multi-view indoor localization via graph location networks[C]//Proceedings of the 28th ACM International Conference on Multimedia. New York: ACM, 2020: 3431-3440.
- [17] LIANG C, ZHANG H X, YUAN D F, et al. Location property of convolutional neural networks for image classification[J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, 32(9): 3831-3845.
- [18] LI Q, LIAO X W, LIU M M, et al. Indoor localization based on CSI fingerprint by Siamese convolution neural network[J]. IEEE Transactions on Vehicular Technology, 2021, 70(11): 12168-12173.
- [19] LI J J, LU K, HUANG Z, et al. Transfer independently together: a generalized framework for domain adaptation[J]. IEEE Transactions on Cybernetics, 2019, 49(6): 2144-2155.
- [20] LIU F, LIU J, YIN Y Q, et al. Survey on WiFi-based indoor positioning techniques[J]. IET Communications, 2020, 14(9): 1372-1383.
- [21] QIU T, LIU J, SI W S, et al. Robustness optimization scheme with multi-population co-evolution for scale-free wireless sensor networks[J]. IEEE/ACM Transactions on Networking, 2019, 27(3): 1028-1042.
- [22] 朱海, 肖甫, 孙力娟, 等. 基于信道状态信息的WiFi环境感知技术[J]. 南京邮电大学学报(自然科学版), 2016, 36(1): 94-103, 110.  
ZHU H, XIAO F, SUN L J, et al. CSI-based WiFi environment sensing[J]. Journal of Nanjing University of Posts and Telecommunications (Natural Science Edition), 2016, 36(1): 94-103, 110.
- [23] GHARAT V, COLIN E, BAUDOIN G, et al. Indoor performance analysis of LF-RFID based positioning system: Comparison with UHF-RFID and UWB[C]//Proceedings of the 2017 International Conference on Indoor Positioning and Indoor Navigation (IPIN). Piscataway: IEEE Press, 2017: 1-8.
- [24] BAHL P, PADMANABHAN V N. RADAR: an in-building RF-based user location and tracking system[C]//Proceedings IEEE INFOCOM 2000. Conference on Computer Communications Nineteenth Annual Joint Conference of the IEEE Computer and Communications Societies (Cat No 00CH37064). Piscataway: IEEE Press, 2000: 775-784.
- [25] 吴泽泰, 蔡仁钦, 徐书燕, 等. 基于K近邻法的WiFi定位研究与改进[J]. 计算机工程, 2017, 43(3): 289-293.  
WU Z T, CAI R Q, XU S Y, et al. Research and improvement of WiFi positioning based on K nearest neighbor method[J]. Computer Engineering, 2017, 43(3): 289-293.
- [26] YOUSSEF M, AGRAWALA A. The Horus WLAN location deter-

- mination system[C]//Proceedings of the 3rd International Conference on Mobile Systems, Applications, and Services. New York: ACM, 2005: 205-218.
- [27] WANG X Y, WANG X Y, MAO S W, et al. Indoor radio map construction and localization with deep Gaussian processes[J]. IEEE Internet of Things Journal, 2020, 7(11): 11238-11249.
- [28] LI D, ZHANG B X, YAO Z, et al. A feature scaling based k-nearest neighbor algorithm for indoor positioning system[C]//Proceedings of the 2014 IEEE Global Communications Conference. Piscataway: IEEE Press, 2015: 436-441.
- [29] WU K S, XIAO J, YI Y W, et al. CSI-based indoor localization[J]. IEEE Transactions on Parallel and Distributed Systems, 2013, 24(7): 1300-1309.
- [30] WU G S, TSENG P H. A deep neural network-based indoor positioning method using channel state information[C]//Proceedings of the 2018 International Conference on Computing, Networking and Communications (ICNC). Piscataway: IEEE Press, 2018: 290-294.
- [31] XIAO J, WU K S, YI Y W, et al. FIFS: fine-grained indoor fingerprinting system[C]//Proceedings of the 2012 21st International Conference on Computer Communications and Networks (ICCCN). Piscataway: IEEE Press, 2012: 1-7.
- [32] WANG J, XIONG J, JIANG H B, et al. Low human-effort, device-free localization with fine-grained subcarrier information[C]//Proceedings of the IEEE Transactions on Mobile Computing. Piscataway: IEEE Press, 2018: 2550-2563.
- [33] HARSHANAND B A, SANGAIAH A K. Comprehensive analysis of deep learning methodology in classification of leukocytes and enhancement using swish activation units[J]. Mobile Networks and Applications, 2020, 25(6): 2302-2320.
- [34] SANGAIAH A K, GOLI A, TIRKOLAE E B, et al. Big data-driven cognitive computing system for optimization of social media analytics[J]. IEEE Access, 2020, 8: 82215-82226.
- [35] WANG X Y, GAO L J, MAO S W, et al. DeepFi: Deep learning for indoor fingerprinting using channel state information[C]//Proceedings of the 2015 IEEE Wireless Communications and Networking Conference (WCNC). Piscataway: IEEE Press, 2015: 1666-1671.
- [36] WANG X Y, GAO L J, MAO S W. CSI phase fingerprinting for indoor localization with a deep learning approach[J]. IEEE Internet of Things Journal, 2016, 3(6): 1113-1123.
- [37] CHEN X, MA C, ALLEGUE M, et al. Taming the inconsistency of Wi-Fi fingerprints for device-free passive indoor localization[C]//Proceedings of the IEEE INFOCOM 2017 - IEEE Conference on Computer Communications. Piscataway: IEEE Press, 2017: 1-9.
- [38] WANG J, ZHANG X, GAO Q H, et al. Device-free wireless localization and activity recognition: a deep learning approach[J]. IEEE Transactions on Vehicular Technology, 2017, 66(7): 6258-6267.
- [39] WANG X Y, WANG X Y, MAO S W. Deep convolutional neural networks for indoor localization with CSI images[J]. IEEE Transactions on Network Science and Engineering, 2020, 7(1): 316-327.
- [40] ZHANG L Y, WU S H, ZHANG T T, et al. Automatic radio map adaptation for robust indoor localization with dynamic adversarial learning[J]. IEEE Transactions on Industrial Informatics, 2025, 21(2): 1615-1624.
- [41] ZHANG L Y, QIU Y F, WU S H, et al. GraphLoc: enhancing fingerprint-based localization with graph representation learning[J]. IEEE Internet of Things Journal, 2025, 12(12): 21593-21603.
- [42] SHOKRY A, TORKI M, YOUSSEF M. DeepLoc: a ubiquitous accurate and low-overhead outdoor cellular localization system[C]//Proceedings of the 26th ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems. New York: ACM, 2018: 339-348.
- [43] CHEN B J, CHANG R Y. Few-shot transfer learning for device-free fingerprinting indoor localization[C]//Proceedings of the ICC 2022 - IEEE International Conference on Communications. Piscataway: IEEE Press, 2022: 4631-4636.
- [44] LI X N, GUO Y, LI F F. Few-shot indoor localization model based on simplified graph convolution and adversarial Gaussian process regression[J]. IEEE Internet of Things Journal, 2025, 12(13): 24490-24502.
- [45] PAN S J, TSANG I W, KWOK J T, et al. Domain adaptation via transfer component analysis[J]. IEEE Transactions on Neural Networks, 2011, 22(2): 199-210.
- [46] LONG M S, WANG J M, DING G G, et al. Transfer feature learning with joint distribution adaptation[C]//Proceedings of the 2013 IEEE International Conference on Computer Vision. Piscataway: IEEE Press, 2014: 2200-2207.
- [47] LIU K, ZHANG H, NG J K, et al. Toward low-overhead fingerprint-based indoor localization via transfer learning: design, implementation, and evaluation[J]. IEEE Transactions on Industrial Informatics, 2018, 14(3): 898-908.
- [48] WANG L, SHAO Y, GUO X S. An adaptive localization approach based on deep adaptation networks[C]//Proceedings of the 2019 International Conference on Control, Automation and Information Sciences (ICCAIS). Piscataway: IEEE Press, 2019: 1-5.
- [49] HALPERIN D, HU W J, SHETH A, et al. Tool release: gathering 802.11n traces with channel state information[J]. ACM SIGCOMM Computer Communication Review, 2011, 41(1): 53.
- [50] BERTINETTO L, VALMADRE J, HENRIQUES J F, et al. Fully-convolutional Siamese networks for object tracking[C]//Computer Vision - ECCV 2016 Workshops. Cham: Springer, 2016: 850-865.
- [51] LIU B, YU X C, ZHANG P Q, et al. Supervised deep feature extraction for hyperspectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2018, 56(4): 1909-1921.
- [52] LUNGU I A, AIMAR A, HU Y H, et al. Siamese networks for few-shot learning on edge embedded devices[J]. IEEE Journal on Emerging and Selected Topics in Circuits and Systems, 2020, 10(4): 488-497.
- [53] WANG X Y, GAO L J, MAO S W, et al. CSI-based fingerprinting for indoor localization: a deep learning approach[J]. IEEE Transactions on Vehicular Technology, 2017, 66(1): 763-776.
- [54] WEI W, YAN J, WU X F, et al. A meta-learning approach for

device-free indoor localization[C]//Proceedings of the IEEE Communications Letters. Piscataway: IEEE Press, 2023: 846-850.

[55] JIAO J Y, WANG X J, HAN C P, et al. Few-shot meta-learning for dynamic indoor fingerprinting localization based on CSI images[C]//Proceedings of the 2025 IEEE Wireless Communications and Networking Conference (WCNC). Piscataway: IEEE Press, 2025: 1-6.

[作者简介]



施政(1987-) 男, 博士, 南京邮电大学通信与信息工程学院副教授, 主要研究方向为智能通信技术、无线光通信及其光电子器件。



王禹(1996-), 男, 博士, 南京邮电大学通信与信息工程学院教授, 主要研究方向为智能信号处理、物理层安全。



夏文超(1991-), 男, 博士, 南京邮电大学副教授, 主要研究方向为边缘智能无线网络、通感一体化、大规模MIMO。



顾浩(1996-), 男, 东南大学集成电路学院博士生, 主要研究方向为基于机器学习辅助的信号处理、室内定位算法、电子设计自动化(EDA)算法。



赵海涛(1983-), 男, 博士, 南京邮电大学物联网学院教授、博士生导师, 主要研究方向为泛在无线通信与物联网、移动通信技术。



黄浩(1994-), 男, 博士, 南京邮电大学通信与信息工程学院讲师, 主要研究方向为智能无线通信、大规模MIMO、无人机通信。



朱洪波(1956-), 男, 《物联网学报》执行主编, 南京邮电大学教授、物联网研究院院长, 中国通信学会物联网专业委员会主任, 中国电子学会通信分会主任, 中国(无锡)物联网研究院院长, 主要研究方向为无线通信网络、移动通信与物联网。