

DOI:10.19651/j.cnki.emt.2313516

# 基于 CNN-GAN 的信道状态信息室内定位算法<sup>\*</sup>

吴雅琴 陈林 侯云峰

(中国矿业大学(北京)机电与信息工程学院 北京 100083)

**摘要:** 在指纹室内定位中,构建高质量的指纹库是实现高精度定位的前提。针对建库阶段需要在每个参考点上收集足够多的信号样本,耗费大量人力与时间成本的问题,提出一种基于改进的条件深度卷积生成对抗网络的指纹库扩充方法。网络模型将参考点序号作为条件信息,得到对应参考点上的生成样本,利用最小二乘损失函数代替交叉熵损失函数,避免训练过程中容易出现的梯度消失问题。实验验证,该方法能有效增加每个参考点的样本数量,提升了卷积神经网络的训练效果,提高了小样本情况下的定位精度,均方根误差降为 0.44 m,定位误差在 1 m 内的占比为 86.98%,误差在 2 m 内的占比为 92.72%。

**关键词:** Wi-Fi 定位;信道状态信息;指纹库;生成对抗网络;卷积神经网络

**中图分类号:** TN92    **文献标识码:** A    **国家标准学科分类代码:** 510.5015

## Channel state information indoor positioning algorithm based on CNN-GAN

Wu Yaqin Chen Lin Hou Yunfeng

(School of Mechanical Electronic and Information Engineering, China University of Mining and Technology (Beijing), Beijing 100083, China)

**Abstract:** In fingerprint indoor positioning, constructing a high-quality fingerprint database is a prerequisite for achieving high-precision positioning. Collecting enough signal samples at each reference point during the fingerprint dataset establishment stage usually consumes a lot of manpower and time costs, to solve this problem, this paper proposes a fingerprint database augmentation method based on an improved conditional deep convolutional generative adversarial network. The network model uses the reference point index as conditional information to generate corresponding samples for each reference point. It uses the least squares loss function instead of the cross-entropy loss function to avoid the problem of gradient disappearance that often occurs during training. Experimental results demonstrate that this method can effectively increase the sample size of each reference point, improve the training effect of the convolutional neural network and the positioning accuracy in small sample cases. The root mean square error is reduced to 0.44 meters, and the proportion of positioning errors within 1 meter is 86.98%, while that within 2 meters is 92.72%.

**Keywords:** Wi-Fi positioning; channel state information; fingerprint database; generative adversarial network; convolutional neural network

## 0 引言

近年来,无线网络和无线设备的普及和发展推动了物联网技术的进步与成熟,定位技术在物联网各种应用场景下的需求也大大提升<sup>[1-2]</sup>。日常生活中许多基于位置的服务,如车辆定位、应急救援、周边商家推荐等都需要对目标进行精确定位<sup>[3]</sup>。定位分为室外定位和室内定位。室外环

境下,全球卫星导航系统可以让用户获得高精度的经纬度和高度信息<sup>[4]</sup>;然而室内环境复杂多变,利用卫星信号无法实现理想的定位效果<sup>[5]</sup>。对此,众多专家学者提出了基于蓝牙<sup>[6]</sup>、红外线、超宽带、RFID<sup>[7]</sup>、Wi-Fi<sup>[8-9]</sup>等的诸多定位方式。随着室内环境中 Wi-Fi 设备的不断普及,基于 Wi-Fi 的指纹定位技术得到了越来越多的关注。

接受信号强度(received signal strength, RSS)是无线

收稿日期:2023-05-01

\* 基金项目:国家自然科学基金重点项目(52130409)、国家重点研发计划项目(2022YFC3004600)资助

信号中的重要指标,常用于衡量连接质量,具有收集方便、对硬件要求低的特点,目前被广泛运用于 Wi-Fi 指纹室内定位系统中。微软研究院提出了第一个利用 RSS 作为指纹的室内定位系统 RADAR<sup>[10]</sup>,该系统利用 K 近邻算法匹配预测用户位置,平均定位误差可达到 5 m 左右。马里兰大学提出的 Horus 定位系统在 RADAR 的基础上与概率方法相结合,获得了更高的定位精度<sup>[11]</sup>。然而 RSS 是粗粒度的信息,且 RSS 在采集过程中受多径传播的影响严重,相同位置的信号随时间产生波动,限制了定位精度<sup>[12]</sup>。和 RSS 相比,信道状态信息(channel state information, CSI)可以获得无线信道中多个子载波更细粒度的物理层信息,受多径效应影响较小,数据更稳定,利用 CSI 特征进行定位可以得到更高的准确度<sup>[13]</sup>。Wang 等<sup>[14]</sup>提出的 DeepFi 定位方法利用深度信念网络提取每个参考点的 CSI 幅值特征,在线阶段通过径向基函数预测目标位置坐标。CiFi<sup>[15]</sup>系统根据 CSI 相位差信息估算出信号的到达角,生成指纹图像,使用卷积神经网络(convolutional neural network, CNN)提取图像特征实现定位。

指纹定位分为离线和在线两个阶段。在离线阶段,收集所有参考点对应的信号特征构建指纹数据库,对指纹库的数据进行分析,建立位置坐标与信号特征间的映射关系。在线阶段,将实时信号与指纹库信号进行比对,利用定位匹配算法得到预测坐标。对于定位匹配算法而言,构建足量的指纹数据库是保证算法能准确预测位置坐标的前提<sup>[16]</sup>,但是采集 Wi-Fi 信号的过程需要消耗大量时间和精力。为了降低数据采集成本,Gu 等<sup>[17]</sup>引入半监督深度极限学习机方法,充分利用众包的无标签数据,提高了定位精度。Zhou 等<sup>[18]</sup>提出的 GrassMA 方法利用 RSS 测量值、位置信息和未标记数据的时间戳信息丰富数据地图。然而上述方法不能减少要采集的样本数量,未标记数据的采集仍需要大量时间。在指纹库中仅有少量标记数据的情况下,可以使用数据扩充方式生成新数据,再将新的数据与原有的指纹数据结合,建立新的指纹库。因此本文提出了一种基于 CNN-GAN 的室内定位算法,提取每个参考点的 CSI 幅值信息,结合条件式生成对抗网络和深度卷积生成对抗网络的优点,利用改进后的条件深度卷积生成对抗网络 (conditional deep convolutional generative adversarial networks, CDCGAN) 对指纹库进行扩展,然后用扩充后的指纹数据对 CNN 进行训练,在不增加采集成本的前提下实现了更好的训练效果,提高了小样本情况下的定位精度。

## 1 数据预处理

### 1.1 CSI 的采集和提取

CSI 描述了无线信号在发送机和接受机之间的通信链路的信道属性,反映了信号在不同传播路径上的衰减情况<sup>[19]</sup>。信道状态信息可以表示为:

$$\mathbf{Y} = \mathbf{H}\mathbf{X} + \mathbf{N} \quad (1)$$

式中: $\mathbf{Y}$  表示接收端信号向量, $\mathbf{X}$  表示发送端信号向量, $\mathbf{H}$  表示 CSI 复矩阵, $\mathbf{N}$  表示额外的高斯白噪声。

如果忽略噪声矩阵  $\mathbf{N}$  的影响,得到 CSI 的计算公式为:

$$\mathbf{H} = \frac{\mathbf{Y}}{\mathbf{X}} \quad (2)$$

通过使用 802.11n 协议和修改配置 Intel 5300 无线网卡的驱动,可以获取 WiFi 设备的 CSI,设置 1 条发送天线和 3 条接收天线,则每个数据包上收集到的 CSI 可以表示为:

$$\mathbf{H} = \begin{bmatrix} \mathbf{H}_{1,1} & \mathbf{H}_{1,2} & \cdots & \mathbf{H}_{1,S} \\ \mathbf{H}_{2,1} & \mathbf{H}_{2,2} & \cdots & \mathbf{H}_{2,S} \\ \mathbf{H}_{3,1} & \mathbf{H}_{3,2} & \cdots & \mathbf{H}_{3,S} \end{bmatrix} \quad (3)$$

式中: $\mathbf{H}_{i,s}$  表示第  $s$  个子载波上第  $i$  条天线接收到的 CSI,对于每一个子载波,可以得到信道频率响应:

$$\mathbf{H}_k = |\mathbf{H}_k| \cdot e^{j\angle \mathbf{H}_k} \quad (4)$$

式中: $\mathbf{H}_k$  表示第  $k$  个子载波的信道状态信息,  $|\mathbf{H}_k|$  和  $\angle \mathbf{H}_k$  分别表示  $\mathbf{H}_k$  的幅值和相位。传播过程中频偏会导致 CSI 的相位偏移,需进行校正处理,本文提取幅值用作定位特征。

### 1.2 CSI 的降噪处理

室内环境复杂多变,受到多径效应和天线间相互干扰的影响,获取的原始 CSI 数据会存在噪声点,影响我们对信号特征的分析,本文选择卡尔曼滤波算法对 CSI 幅值进行降噪处理以提高定位精度。

卡尔曼滤波算法是基于最小均方误差为预测准则来寻求递归更新的一种优化算法。其核心在于综合先验信息和测量信息,得出最优估计,从而计算出接近真实状态的估计值。卡尔曼滤波主要分为预测和校正两个环节,预测环节的更新方程如下:

$$\hat{x}_k = \mathbf{A}\hat{x}_{k-1} + \mathbf{B}u_k \quad (5)$$

$$\mathbf{P}_k^- = \mathbf{A}\mathbf{P}_{k-1}\mathbf{A}^T + \mathbf{Q} \quad (6)$$

式中: $\mathbf{A}$  为状态转移矩阵,  $\hat{x}_{k-1}$  和  $\hat{x}_{k-1}^-$  分别是当前时刻  $k$  和上一时刻  $k-1$  的系统状态预测值,  $\mathbf{B}$  为控制矩阵,  $u_k$  为当前时刻系统状态控制量;  $\mathbf{P}_k^-$  表示由上一时刻对当前时刻误差协方差的估计,  $\mathbf{A}^T$  表示  $\mathbf{A}$  的转置矩阵,  $\mathbf{Q}$  是系统噪声协方差矩阵。

校正环节的更新方程如下:

$$\hat{x}_k = \hat{x}_k^- + \mathbf{K}_k(z_k - \mathbf{H}\hat{x}_k^-) \quad (7)$$

$$\mathbf{K}_k = \frac{\mathbf{P}_k \mathbf{H}^T}{\mathbf{H} \mathbf{P}_k \mathbf{H}^T + \mathbf{R}} \quad (8)$$

$$\mathbf{P}_k = (\mathbf{I} - \mathbf{K}_k \mathbf{H}) \mathbf{P}_k^- \quad (9)$$

式中: $\mathbf{K}_k$  表示  $k$  时刻的卡尔曼增益,通过权衡预测状态协方差  $\mathbf{P}_k$  和测量噪声协方差  $\mathbf{R}$  的大小来决定更相信预测模型还是观察模型,  $\mathbf{H}$  为系统的测量矩阵;  $\hat{x}_k$  为滤波后的状态值,  $z_k$  为  $k$  时刻的测量值;  $\mathbf{P}_k$  是  $\hat{x}_k$  对应的当前时刻的系

统噪声协方差矩阵,  $\mathbf{I}$  表示单位矩阵。

本文利用卡尔曼滤波算法的思想建立对应于 CSI 幅值预处理的状态空间模型, 具体步骤为:

1) 若每个参考点上某一天线采集了  $M$  条数据, 根据 CSI 复数矩阵计算  $M$  条数据  $N$  个子载波的幅值:

$$\begin{bmatrix} \mathbf{Amp}_{1,1} & \mathbf{Amp}_{1,2} & \cdots & \mathbf{Amp}_{1,N} \\ \mathbf{Amp}_{2,1} & \mathbf{Amp}_{2,2} & \cdots & \mathbf{Amp}_{2,N} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{Amp}_{M,1} & \mathbf{Amp}_{M,2} & \cdots & \mathbf{Amp}_{M,N} \end{bmatrix} = \mathbf{amp}(\mathbf{H}) \quad (10)$$

2) 根据第  $m-1$  条数据的子载波幅值  $\mathbf{Amp}_{m-1,n}$  去估计第  $m$  条数据子载波幅值  $\mathbf{Amp}_{m,n}$ ;

3) 根据系统噪声推算误差协方差并计算卡尔曼增益;

4) 结合卡尔曼增益和测量值, 对第  $m$  条数据子载波幅值  $\mathbf{Amp}_{m,n}$  进行校正更新;

5) 对协方差进行更新;

6) 不断迭代, 直到处理完  $N$  个子载波的幅值数据。

图 1(a) 为某天线原始 CSI 幅值图像, 图 1(b) 为经过卡尔曼滤波处理后的效果图, 经过降噪操作后, 信号的特征趋势不变, 幅值曲线更加平滑, 减小了噪声干扰。

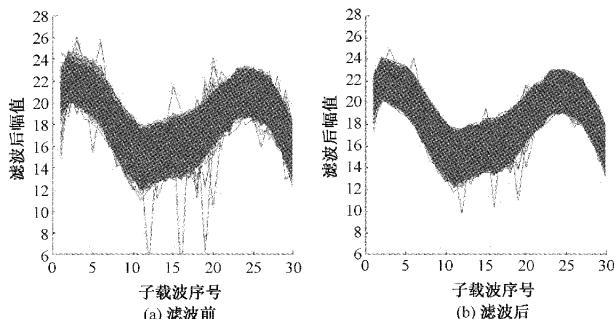


图 1 CSI 降噪前后对比

### 1.3 指纹库构建

利用降噪后的 CSI 幅值信息来构建指纹数据库, 每个幅值矩阵的尺寸为  $30 \times 30 \times 3$ , 构建方法为:

$$\mathbf{Am}_n = \begin{bmatrix} \mathbf{Am}_{1,1} & \mathbf{Am}_{2,1} & \mathbf{Am}_{3,1} \\ \mathbf{Am}_{1,2} & \mathbf{Am}_{2,2} & \mathbf{Am}_{3,2} \\ \vdots & \vdots & \vdots \\ \mathbf{Am}_{1,30} & \mathbf{Am}_{2,30} & \mathbf{Am}_{3,30} \end{bmatrix}_{30 \times 3} \quad (11)$$

式中:  $n$  表示采集次数,  $\mathbf{Am}_n$  表示第  $n$  次采集的幅值信息, 矩阵中  $\mathbf{Am}_{i,j}$  表示第  $i$  条接受天线的第  $j$  个子载波的幅度信息。如果进行了  $N$  次采集, 且  $N/30$  等于一个整数  $K$ , 那么可以将每 30 个数据包拼接成一个幅值矩阵:

$$\mathbf{A}_i = [\mathbf{Am}_1 \ \mathbf{Am}_{n-1} \ \cdots \ \mathbf{Am}_{n+29}]_{30 \times 30 \times 3} \quad (12)$$

将幅值矩阵进行组合:

$$\mathbf{T}_a = [\mathbf{Am}_1 \ \mathbf{Am}_2 \ \cdots \ \mathbf{Am}_K]_{30 \times 30 \times 3 \times K} \quad (13)$$

$\mathbf{T}_a$  为一个参考点上所构建出的指纹数据, 被用于 CNN 训练定位模型。

## 2 CNN-GAN 定位算法设计

### 2.1 算法流程

本文提出的定位方法包括指纹库构建、数据扩充、定位模型训练和在线预测 4 个阶段。采集每个参考点的 CSI 信号, 利用经过卡尔曼滤波算法去噪后的 CSI 幅值构建指纹库; 通过改进的 CDCGAN 对每个参考点生成新数据, 将初始指纹库和新生成数据合并得到扩充后的指纹库; 使用扩充后的指纹库训练 CNN 参数, 得到理想的定位模型; 将实时采集的 CSI 数据进行去噪处理, 输入到训练好的定位模型中, 得到最终的预测坐标。算法流程如图 2 所示。

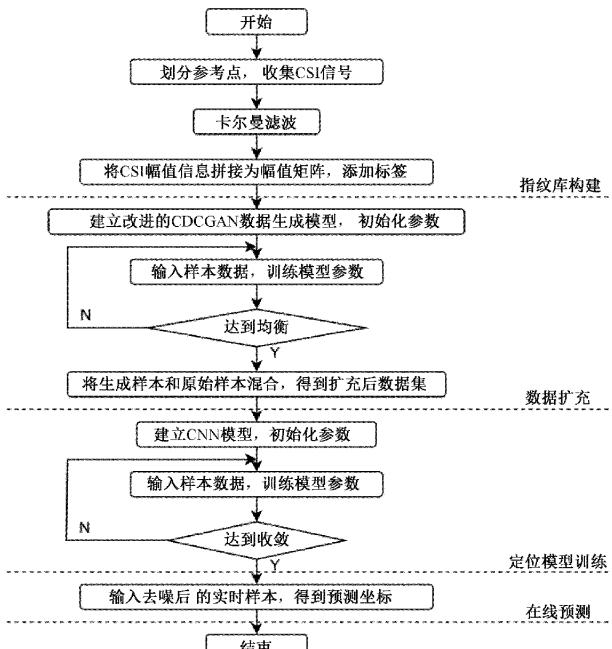


图 2 基于 CNN-GAN 的指纹定位算法流程

### 2.2 基于 GAN 的数据生成模型

对于指纹室内定位系统, 各参考点均匀分布且每个参考点具有足够的数据量是保证高精度定位的前提。收集数据时, 参考点应尽量覆盖且均匀分布于待定位区域, 采集过程需要消耗大量的人力物力, 样本量不足时, 匹配算法的网络容易发生过拟合, 导致在线阶段定位精度低。GAN 能通过对真实样本数据的分布进行估计<sup>[20]</sup>, 生成新的数据样本, 扩充数据集, 降低数据收集成本, 同时保证定位模型的泛化能力。

GAN 是一种生成式模型<sup>[21]</sup>, 由一对相互对抗的生成器  $G$  和判别器  $D$  组成。生成器  $G$  试图学习真实数据的分布并产生新的生成数据, 判别器则试图判断传入的数据是真实数据还是生成器生成的伪造数据, GAN 训练的目标函数为:

$$\min_{G} \max_{D} V(D, G) = E_{x \sim P_{data}(x)} [\log(D(x))] + E_{z \sim p_z(z)} [\log(1 - D(G(z)))] \quad (14)$$

式中:  $z$  和  $x$  分别表示噪声和真实数据,  $P_{data}(x)$  和  $p_z(z)$

分别为真实数据和生成数据的样本分布,  $G(z)$  表示生成器的输出,  $D(x)$  表示判别器的输出。在此基础上,二者不断对抗学习以获得更强的生成新样本能力和判别能力,直至达到纳什均衡,此时生成器可以产生出判别器难以区分的生成数据。

原始 GAN 网络没有对输入的数据进行任何限制,直接输入随机噪声,因此输出为随机样本,无法对生成的样本属性进行选择。条件生成对抗网络(conditional generative adversarial network, CGAN)是原始 GAN 的衍生模型<sup>[22]</sup>,通过引入额外的类别信息添加条件,分别与真实数据和随机向量结合,输入到生成器 G 和判别器 D 中,可以生成多种类别的数据,在 GAN 的目标函数中引入标签信息可以得到 CGAN 的目标函数:

$$\min_{G} \max_{D} V(D, G) = E_{x \sim P_{data}(x)} [\log(D(x | Y))] + E_{z \sim p_z(z)} [\log(1 - D(G(z | Y)))] \quad (15)$$

GAN 的网络结构是全连接层,每一层的参数数量较多,DCGAN 与 GAN 的训练思想相同,但将卷积网络引入到生成器和判别器中,网络更稳定且收敛速度更快。

对于 CSI 指纹室内定位,一般在实验区域内设置众多参考点,不同参考点上 CSI 幅值特征各异。本文结合 CGAN 和 DCGAN 的优势,运用最小二乘损失函数,得到优化的 CDCGAN。该方法能够对每个参考点生成与原始幅值样本相似的新样本,为之后匹配模型的训练提供更多有效样本。网络借鉴 DCGAN 的网络架构,用卷积层替代全连接层,可以更好地提取 CSI 幅值特征,同时减少训练参数数量,加快了模型的训练速度;在生成器输入的随机向量中融入参考点的位置信息,对输出数据的类别进行引导,生成对应参考点上的 CSI 幅值样本;利用最小二乘损失函数代替原始 GAN 所采用的 Sigmoid 交叉熵损失函数,对判定为真但远离决策边界的的数据进行处理,有效避免梯度消失问题。生成器和判别器的损失函数如下:

$$\begin{cases} \min_D V(D) = \frac{1}{2} E_{x \sim P_{data}(x)} [(D(x | Y) - a)^2] + \\ \frac{1}{2} E_{x \sim P_z(z)} [D(G(z | Y) - b)^2] \\ \min_G V(G) = \frac{1}{2} E_{z \sim P_z(z)} [(D(G(z | Y)) - c)^2] \end{cases} \quad (16)$$

式中:  $D$  代表判别器,  $G$  代表生成器,  $z$  为服从标准正态分布的随机变量,常数  $a$  和  $b$  分别表示真实数据和生成数据的标签,  $c$  是生成器期望判别器认为生成数据是真实数据所定的值,取  $b=0, a=c=1$ 。

生成器和判别器的网络结构如图 3 和 4 所示。

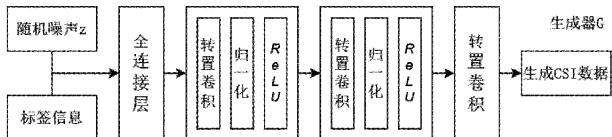


图 3 生成器网络结构

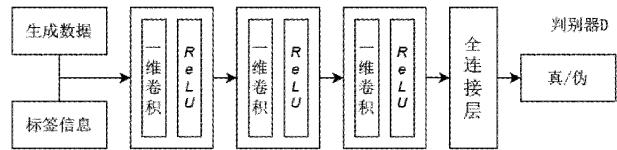


图 4 判别器网络结构

生成器模型和判别器模型都由 6 层神经网络构成,包括 1 个输入层、1 个输出层和 4 个隐藏层,其中生成器模型的输入噪声向量是多维的随机向量,维度选为 48,条件信息为幅值所属的参考点编号,隐藏层由全连接层和转置卷积层组成,输出为新生成的对应编号位置的 CSI 幅值信息。判别器模型的输入为 CSI 幅值特征与标签信息的结合数据,隐藏层由一维卷积层和全连接层组成,输出为判断样本为真的可能性。具体参数如表 1 所示。

表 1 生成器和判别器的网络参数

组成部分	结构	网络参数	激活函数	输出尺寸
生成器	全连接层	—	—	$32 \times 10$
	转置卷积层一	卷积核-3 步长-2	ReLU	$8 \times 21$
	转置卷积层二	卷积核-4 步长-2	ReLU	$4 \times 44$
	转置卷积层三	卷积核-4 步长-2	ReLU	$1 \times 90$
判别器	卷积层一	卷积核-3 步长-2	ReLU	$4 \times 53$
	卷积层二	卷积核-4 步长-2	ReLU	$8 \times 26$
	卷积层三	卷积核-4 步长-2	ReLU	$32 \times 13$
	全连接层	—	—	1

### 2.3 基于 CNN 的位置预测模型

利用上文的数据生成方法,对每个参考点上的 CSI 样本进行扩充,得到新的指纹库。在指纹定位中,指纹数据库的质量和具体匹配方法共同决定了最终的定位效果,近年来,CNN 在各种分类任务中展现出出色的性能而被广泛应用,本文选择在离线阶段将扩充后的数据集输入 CNN 进行训练,学习 CSI 特征矩阵与对应位置标签的映射关系。CNN 网络由 1 个输入层,4 个卷积层,2 个全连接层和 1 个输出层构成。输入层的输入为  $3 \times 30 \times 30$  的 CSI 矩阵,4 个卷积层的卷积核尺寸都为  $3 \times 3$ ,最后经过 2 个全连接层,输出值使用 softmax 逻辑回归得到每一类的概率,类别数量为参考点的个数。具体参数如表 2 所示。

表 2 CNN 网络参数

结构	卷积核	步长	激活函数	Drop-out	输出尺寸
卷积层一	$3 \times 3$	1	LeakyReLU	0.25	$8 \times 30 \times 30$
卷积层二	$3 \times 3$	1	LeakyReLU	0.25	$8 \times 30 \times 30$
卷积层三	$3 \times 3$	1	LeakyReLU	0.25	$16 \times 28 \times 28$
卷积层四	$3 \times 3$	2	LeakyReLU	0.25	$32 \times 13 \times 13$
全连接层	—	—	—	—	Nrp

在线阶段, 收集测试点上的实时 CSI 数据, 并进行与训练数据相同的数据预处理方式, 处理后的数据输入训练好的 CNN 模型中, 输出目标位置位于每个参考点的概率, 将每个点输出概率同对应坐标加权求和, 得到预测坐标。

### 3 实验验证与结果分析

#### 3.1 实验设计

为验证本文提出的定位算法在实际环境中的有效性, 选择在室内走廊环境中进行实验, 实验区域的大小为  $5\text{ m} \times 7\text{ m}$ , 共设置 165 个参考点, 相邻参考点间距为  $0.5\text{ m}$ , 场景示意图如图 5 所示。

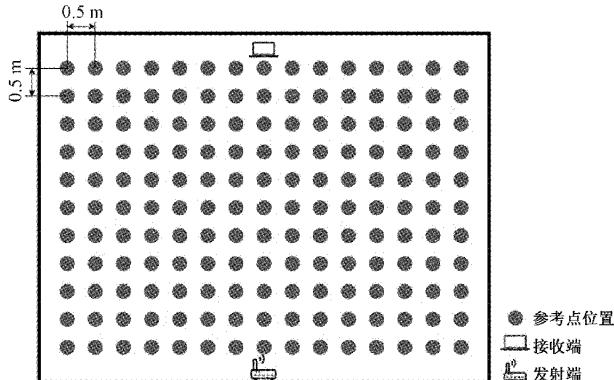


图 5 实验场景示意图

使用 Intel 5300 网卡采集 CSI 信息, 并外接 3 条天线, 将装有该网卡的 DELL 15HR 笔记本电脑作为信号接收端, 一台 MERCURY MW325R 无线路由器作为信号发射端, 发射端有 1 条发射天线。采集过程中发射端和接受端的位置固定, 测试人员站在每个参考点保持静止, 通过在接收端输入指令采集 CSI 数据。每个参考点采集 CSI 数据包 6 000 个, 选取其中 50% 的样本作为训练数据集, 10% 的样本作为验证数据集, 另外 40% 的样本作为测试数据集。在线阶段使用测试样本从均方根误差 (root mean square error, RMSE) 和累计分布函数 (cumulative distribution function, CDF) 对算法进行定位性能评估。

#### 3.2 实验结果分析

##### 1) 数据预处理的影响

本文选用卡尔曼滤波算法对数据进行去噪处理, 为评估去噪效果, 分别利用原始数据和去噪后数据进行 CNN 模型训练和在线定位测试, 它们的定位误差累计分布函数如图 6 所示, 可以看出, 经过去噪处理后定位性能略优于去噪前。

表 3 为去噪前后的定位均方根误差, 去噪后的均方根误差比去噪前低  $0.06\text{ m}$ 。实验证明原始数据中存在的噪声确实会对定位精度产生影响, 对采集到的 CSI 数据进行去噪处理能够在一定程度上提高定位精度, 本文的去噪操作是有效的。

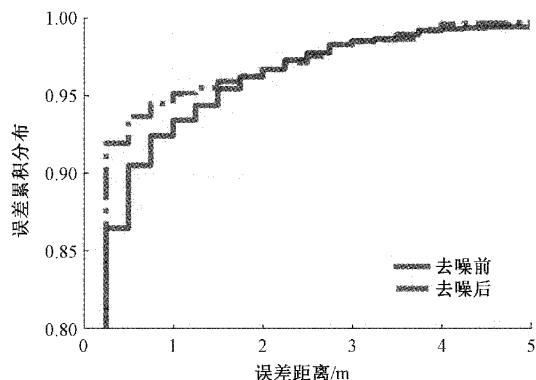


图 6 去噪前后定位效果对比

表 3 去噪前后定位误差

预处理情况	均方根误差/m
未经过预处理	0.22
经过预处理	0.16

##### 2) 训练样本数量的影响

为研究指纹库的样本量对定位精度的影响, 创建四个训练集, 每个参考点分别包含 600、1 200、1 800 和 3 000 条 CSI 样本。再利用这 4 个训练集依次对 CNN 模型进行训练, 对比在同一测试集下的定位效果。图 7 与 8 为不同样本量下的定位性能对比。

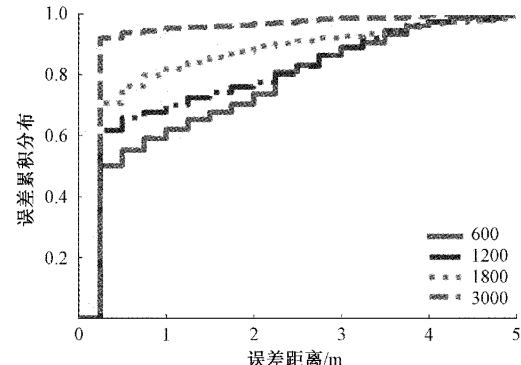


图 7 不同样本数量的定位效果对比

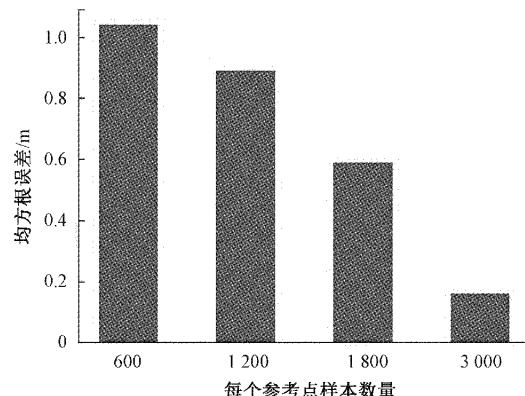


图 8 不同样本数量的定位误差对比

可以看出,样本数量对定位性能影响明显,在 CSI 样本数最少的情况下,CNN 模型分类能力最差,定位误差也最大,均方根误差达到 1.04 m。随着样本数量增多,模型分类能力增强,定位效果逐渐提高,在 CSI 样本数最多的时候,CNN 模型分类能力最强,定位误差最小,为 0.16 m。

### 3) 生成样本数量的影响

为验证本文提出的指纹库扩充方案的有效性,每个参考点取 1 200 条 CSI 幅值样本作为初始离线样本集,将离线样本集扩充至初始数量的 2 倍、3 倍、4 倍,分别用作 CNN 模型的训练集,对比在同一测试集下的定位效果。最终它们的 CDF 曲线对比图如图 9 所示,均方根误差结果如图 10 所示。

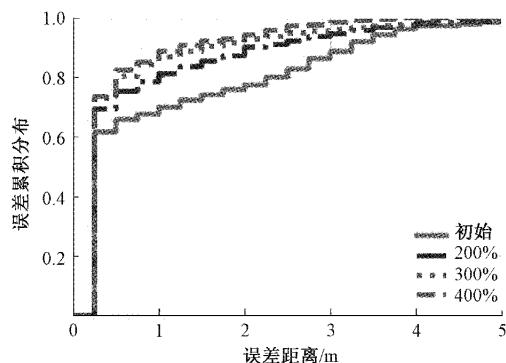


图 9 不同生成样本数量的定位效果对比

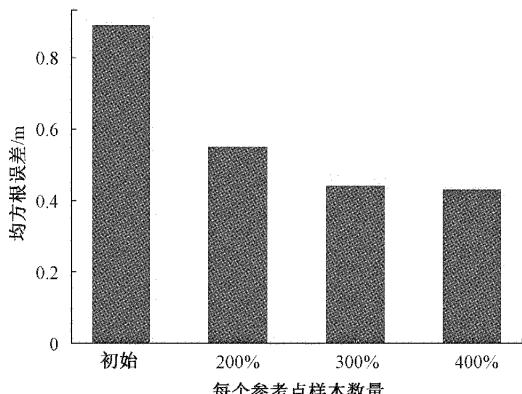


图 10 不同生成样本数量的定位误差对比

可以看出,使用初始样本集训练定位模型,均方根误差为 0.89 m,测试点中误差距离在 0.25 m 以内的比例为 61.52%,误差距离在 1 m 以内的比例为 69.82%。使用扩充至初始数量 2 倍的指纹库,均方根误差为 0.55 m,测试点中误差距离在 0.25 m 以内的比例为 69.33%,误差距离在 1 m 以内的比例为 81.39%。使用扩充至初始数量 3 倍的指纹库,均方根误差为 0.44 m,测试点中误差距离在 0.25 m 以内的比例为 72.80%,误差距离在 1 m 以内的比例为 86.98%。实验表明扩充离线样本集提升了定位效果,且随着生成样本数的增加,定位效果也越来越好。但是当生成样本数增加到一定程度后,定位效果不再有提升,如

本实验中将初始指纹库扩充至 3 倍与 4 倍最终定位效果相差不大,说明指纹库已趋于饱和。

### 4) 真实 CSI 数据量对扩展库的影响

为对比真实 CSI 的数据量对指纹库扩展的影响,取不同数量的真实样本作为初始离线样本集,进行数据扩充,对比定位效果的差异。初始样本集的真实 CSI 样本数量分别为每个参考点 600、1 200 和 2 400 条,扩充后的指纹库每个参考点样本数量均为 4 800 条。均方根误差结果对比如图 11 所示。

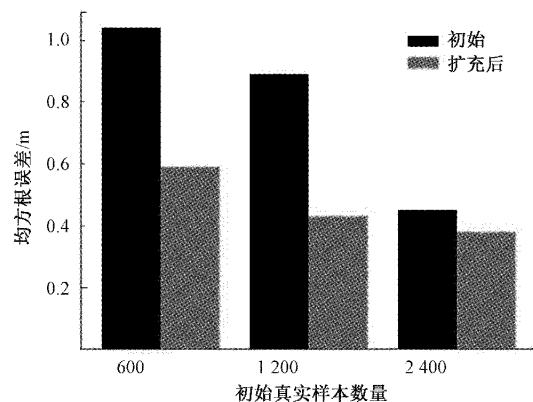


图 11 不同生成样本数量的定位误差对比

可以看出,经过数据扩充后的指纹库的定位效果都得到了较大提升,同时真实 CSI 样本数量越少,效果提升程度就越明显。而真实样本数量越多,整体定位效果越好,这主要是因为当 CSI 样本数量较少时,GAN 的学习能力受限,导致生成的 CSI 误差较大。增加 CSI 样本数量可以减小误差,但这也会增加离线采集阶段所需的人力和时间成本。

### 5) 不同定位算法的对比

将本文提出的基于 CNN-GAN 的室内定位算法与常用的基于 CSI 的 DeepFi 和 CiFi 指纹定位方法进行对比,分析其性能差异。实验所用的指纹库每个参考点包含 1 200 条 CSI 样本,图 12 给出了 3 种定位方式的 CDF 曲线对比图,表 4 为不同定位方法下的定位均方根误差。

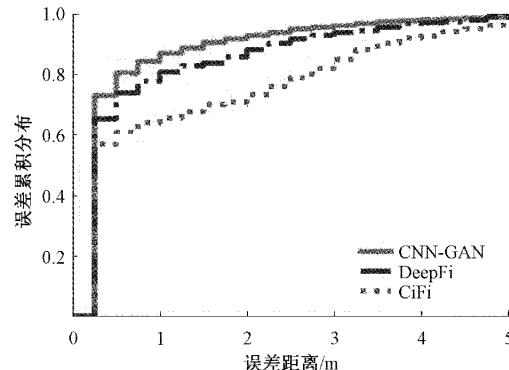


图 12 不同定位方法的定位效果对比

表 4 不同定位方法的定位误差

定位方法	CNN-GAN	DeepFi	CiFi
均方根误差/m	0.44	0.61	1.09

从图 12 的曲线对比和表 4 的数据可以看出, 使用本文算法, 定位误差在 1 m 和 2 m 内的置信概率分别为 86.98% 和 92.72%, 而使用 DeepFi 和 CiFi 方法, 定位误差在 1 m 内的概率分别为 80.60% 和 65.59%, 误差在 2 m 内的概率分别为 88.24% 和 73.23%。另外, 本文算法的均方根误差为 0.44 m, DeepFi 和 CiFi 方法的均方根误差分别为 0.61 m 和 1.09 m。在误差累计分布和平均定位误差方面本文算法明显优于其他两种算法。实验结果进一步验证了本文提出的 CNN-GAN 定位算法在小样本下获得了更好的定位效果。

## 4 结 论

本文将 CSI 幅值作为特征, 提出一种基于 CNN-GAN 的指纹室内定位方法。通过卡尔曼滤波算法对采集到的原始信号进行去噪处理, 以得到洁净的指纹数据。使用优化的 CDCGAN 对指纹数据库进行扩充, 增加样本数量, 利用扩充后的 CSI 特征图像训练 CNN 定位模型, 用于在线阶段位置坐标的预测。在真实环境中采集 CSI 数据进行实验, 结果表明, 基于生成对抗网络的数据增强方法能够提高小样本情况下的定位精度, 通过与基于 CSI 定位的 DeepFi 和 CiFi 算法进行实验对比, 结果验证了本文所提出算法在定位精度上存在较大优势。但室内环境随时可能发生改变, 当出现新的物体或人时, 指纹库的准确性和可靠性会受到不同程度的影响。计划之后在本文研究工作的基础上增加对 CSI 指纹库时效性的研究。

## 参考文献

- [1] ZHU X, QU W, QIU T, et al. Indoor intelligent fingerprint-based localization: Principles, approaches and challenges[J]. IEEE Communications Surveys & Tutorials, 2020, 22(4): 2634-2657.
- [2] GUO X, LI L, ANSARI N, et al. Accurate WiFi localization by fusing a group of fingerprints via a global fusion profile [J]. IEEE Transactions on Vehicular Technology, 2018, 67(8): 7314-7325.
- [3] 吴雅琴, 师兰兰. 基于 LoRa 的火灾救援现场人员定位算法研究[J]. 计算机应用与软件, 2020, 37(6): 70-75.
- [4] 宁津生, 姚宜斌, 张小红. 全球导航卫星系统发展综述[J]. 导航定位学报, 2013, 1(1): 3-8.
- [5] FARID Z, NORDIN R, ISMAIL M. Recent advances in wireless indoor localization techniques and system [J]. Computer Networks and Communications, 2013, (2013-9-22), 2013, 2013: 15-15.
- [6] FARAGHER R, HARLE R. Location fingerprinting with bluetooth low energy beacons[J]. IEEE Selected Areas in Communications Journal, 2015, 33(11): 2418-2428.
- [7] 孟强, 徐慧. 基于 RFID 的定位技术[J]. 电脑知识与技术, 2013, 1: 158-161.
- [8] 陈禹, 渠吉庆, 唐文静, 等. 基于 LSTM 的室内定位系统设计与实现[J]. 电子测量技术, 2021, 44(19): 161-166.
- [9] XU Y, DAVID K. When indoor localization meets new communication technologies [C]. 2019 IEEE 90th Vehicular Technology Conference (VTC2019-Fall), 2019: 1-4.
- [10] BAHL P, PADMANABHAN V. RADAR: An in-building RF-based user location and tracking system[C]. IEEE INFOCOM 2000, Conference on Computer Communications. Nineteenth Annual Joint Conference of the IEEE Computer and Communications Societies, 2000(2): 775-784.
- [11] YOUSSEF M, AGRAWALA A. The horus location determination system [J]. Wirel Networks, 2008, 14(3): 357.
- [12] SOBEHY A, RENAULT É, MÜHLETHALER P. CSI-MIMO: K-nearest neighbor applied to indoor localization[C]. ICC 2020-2020 IEEE International Conference on Communications(ICC), 2020: 1-6.
- [13] SONG Q, GUO S, LIU X, et al. CSI amplitude fingerprinting-based NB-IoT indoor localization [J]. IEEE Internet of Things Journal, 2018, 5 (3): 1494-1504.
- [14] WANG X, GAO L, MAO S, et al. DeepFi: Deep learning for indoor fingerprinting using channel state information[C]. 2015 IEEE Wireless Communications and Networking Conference(WCNC), New Orleans, 2015: 1666-1671.
- [15] WANG X, WANG X, MAO S. CiFi: Deep convolutional neural networks for indoor localization with 5 GHz Wi-Fi [C]. 2017 IEEE International Conference on Communications(ICC), IEEE, 2017: 1-6.
- [16] ZHANG Y X, ZHU Y, LU M M, et al. Using compressive sensing to reduce fingerprint collection for indoor localization[C]. IEEE Wireless Communications

- and Networking Conference(WCNC), 2013: 4540-4545.
- [17] GU Y, CHEN Y, LIU J, et al. Semi-supervised deep extreme learning machine for Wi-Fi based localization[J]. Neurocomputing, 2015, 166: 282-293.
- [18] ZHOU M, TANG Y, NIE W, et al. GrassMA: Graph-based semi-supervised manifold alignment for indoor WLAN localization[J]. IEEE Sensors Journal, 2017, 17(21): 7086-7095.
- [19] XIA P, ZHOU S, GIANNAKIS G. Adaptive MIMO-OFDM based on partial channel state information[J]. IEEE Transactions on Signal Processing, 2004, 52(1): 202-213.
- [20] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks[J]. Communications of the ACM, 2020, 63(11): 139-144.
- [21] 王坤峰,苟超,段艳杰,等.生成式对抗网络GAN的研究进展与展望[J].自动化学报,2017,43(3):321-332.
- [22] MIRZA M, OSINDERO S. Conditional generative adversarial nets[J]. Computer Science, November. 2014, 2672-2680.

### 作者简介

吴雅琴,教授,主要研究方向为人工智能、物联网技术、信息融合。

E-mail:wyqcumt@126.com

陈林,硕士研究生,主要研究方向为物联网技术。

E-mail:chenlincumtb@sina.com

侯云峰,硕士研究生,主要研究方向为计算机视觉。

E-mail:1762263688@qq.com