

DOI: 10.19650/j.cnki.cjsi.J2311986

基于改进对比学习和并行融合神经网络的 室内 WiFi 定位算法*

蒲巧林, 陈有坤, 周 牧, 余征巍, 张钰坤

(重庆邮电大学通信与信息工程学院 重庆 400065)

摘 要:机器学习在 WiFi 指纹定位技术中扮演着重要角色。针对信号波动对指纹辨识力的影响往往被忽略以及如何从样本中提取更广泛的表征信息的问题,提出了一种基于改进对比学习(CL)和并行融合神经网络的 WiFi 定位算法。该算法首先利用改进对比学习来提高指纹辨识力,其在增加不同类别指纹间的区分度的同时能减小同类别指纹间的差异。其次,构建基于卷积神经网络(CNN)和长短期记忆(LSTM)的并行融合网络,与传统的串行融合方式相比,网络可以从原始样本中提取更多的有效特征。此外,在池化层后增加 Flatten 层以进一步考虑网络的中间层信息,从而利用更广泛的特征信息来提高模型的泛化性能。结果表明,所提算法的定位性能比其他定位算法提高 26%。

关键词:室内定位;对比学习;卷积神经网络;长短期记忆;特征融合

中图分类号: TN92 TH89 **文献标识码:** A **国家标准学科分类代码:** 510.99

Indoor WiFi localization algorithm based on the improved contrastive learning and parallel fusion neural network

Pu Qiaolin, Chen Youkun, Zhou Mu, Yu Zhengwei, Zhang Yukun

(School of Communications and Information Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)

Abstract: Machine learning plays an important role in WiFi fingerprint localization techniques. To address the problem that the effect of signal fluctuation on fingerprint recognition is often ignored and how to extract broader representation information from samples, this article proposes a WiFi localization algorithm based on improved contrastive learning and parallel fusion neural network. Firstly, the algorithm utilizes the improved CL to improve fingerprint discrimination, which increases the differentiation between different categories of fingerprints while reducing the differences between fingerprints of the same category. Secondly, a parallel fusion network based on CNN and LSTM is established. Compared with the traditional serial fusion method, the network can extract more effective features from the original samples. In addition, a flatten layer is added after the pooling layer to further consider the intermediate layer information of the network. Thus, a wider range of feature information is utilized to improve the generalization performance of the model. The results show that the proposed algorithm improves the localization performance by 26% over other localization algorithms.

Keywords: indoor localization; CL; CNN; LSTM; feature fusion

0 引 言

5G 时代的来临,推动了智慧化城市的快速发展。随着人们对定位与导航需求的日益增大,基于位置的服务(location-based service, LBS)变得越来越重要^[1]。现如

今,全球定位系统(global positioning system, GPS)已经趋于成熟。然而,由于室内环境中存在障碍物,卫星信号大幅度衰减而无法工作。而人们大部分时间是在室内环境中度过的,因此对于室内的位置服务需求更加迫切。近年来,基于 WiFi^[2]、红外线^[3]、超声波^[4]、蓝牙^[5]、Zigbee^[6]等室内定位技术得到了长足发展。特别是基于

WiFi 的室内定位技术因其部署成本低、定位精度高的优势受到相关人员的青睐。WiFi 定位方法大致分基于测距的定位方法和基于非测距的定位方法两类。基于测距的定位方法主要包括到达时间 (time of arrive, TOA)、到达时间差 (time difference of arrive, TDOA)、到达角度 (angle of arrive, AOA) 以及信号传播模型法。基于非测距的定位方法主要是位置指纹定位。与基于测距的方法相比, 指纹定位方法因其简单的系统操作和测量采集而被广泛使用。

无论使用传统的定位方法还是深度学习方法, 样本之间的差异在定位系统中都非常重要, 这意味着不同参考点 (reference points, RPs) 之间的指纹应该是不同的^[7]。然而, 由于信号波动, 一些收集的样本数据包含了重叠带来的大量冗余信息。尽管深度学习技术可以通过特征提取在一定程度上解决这个问题, 但无法保证使用原始数据进行直接训练的良好性能, 因为基于它的特征提取过程是一个盲盒。因此, 在将原始样本数据输入到神经网络之前, 往往需要通过数据处理来提高指纹辨识力, 例如传统的线性或非线性数据处理方法。经典的线性处理方法有主成分分析 (principal component analysis, PCA)^[8] 和线性判别分析 (linear discriminant analysis, LDA)^[9]。上述方法虽然在一定程度上提高了指纹的区分度, 但是只能反映输入空间到输出空间的线性关系, 而且计算量较大。为了提取非线性因素, 一方面, 一些工作利用核函数对线性方法进行了修改。文献[10]利用核主成分分析 (kernel principal component analysis, KPCA) 提取非线性特征, 但其需要对所有样本求和, 计算开销较大。另一方面, 流形学习 (manifold learning, ML) 被一些研究人员引入。文献[11]中, 流形学习被用来从噪声接收信号强度 (received signal strength indicator, RSSI) 观测中重建其流形的稀疏表示, 并引入了多尺度约束二次规划来近似流形, 从而利用学习到的流形来预测用户的位置。尽管这些处理方法可以提取非线性分量, 但无法构建从输入空间到输出空间的显式映射模型, 因此它们不能应用于与样本具有未知关系的新数据, 也就是说, 无法保证定位系统的鲁棒性。

由于指纹定位对 RSSI 数据的波动较为敏感, 因此学者们提出基于深度学习的定位算法, 利用神经网络可以挖掘数据更深层次特征的优势, 从而提高定位精度和鲁棒性。传统的卷积神经网络 (convolutional neural networks, CNN) 作为一种经典的深度学习模型, 被广泛用来提取样本数据的空间特征^[12]。然而, 其缺点是不能反映样本之间的时间关联性, 因此其定位精度难以进一步提高。另一方面, 为了利用时间特征, 长短期记忆网络 (long short-term memory, LSTM) 被引入到定位系统中^[13], 它通过遗忘门选择性地丢弃信息以确保信息的持

久性。然而, 它们具有单一神经网络带来的劣势, 即只能提取单一特征。为了解决这个问题, 文献[14]提出一种结合残差网络和 LSTM 网络的时空定位算法, 它可以提取 RSSI 测量值的空间和时间特征, 从而进一步提升模型的定位性能。然而, 这些融合网络总是串行连接, 并且忽略了神经网络中间层的大量可用信息, 而这些信息对定位也是有价值的。

因此, 为了应对信号波动及充分提取并利用样本数据隐含的信息, 本文提出了一种基于改进的对比学习 (contrastive learning, CL) 和并行融合神经网络的室内 WiFi 定位算法, 命名为 PaCNN-LSTM。首先利用改进的 CL 对样本数据进行预处理, 以提高指纹辨识力。与传统的线性或非线性处理方法相比, CL 从学习和编码的角度通过让网络模型学习 RSSI 之间的相似性或差异性来获得表征向量。值得注意的是, CL 不仅适用于线性不可分的样本, 而且不要求输入空间内的数据具有意义的距离度量。然后, 通过并行的方式将 CNN 和 LSTM 结合起来, 并在池化层之后增加了 Flatten 层, 以充分利用中间层的大量可用信息。最后, 将提取的空间特征、时间特征和中间层特征全部合并到全连接层中用于定位。

本文在考虑指纹辨识力时引入 CL 框架来处理样本数据。与传统的线性或非线性数据处理方法不同, 它是从学习和编码的角度出发, 可以避免传统方法带来的弊端。此外, 通过将数据增强模块替换为数据筛选模块来改进经典的 CL, 从而使学习模型变得易于处理, 并且在定位系统中比经典模型更实用。本文利用 CNN 和 LSTM 构造了一种新的融合网络, 该网络通过并行而不是串行的方式进行连接。与现有的串联融合网络相比, 在提取空间和时间特征时可以提高模型的泛化性能, 更有利于定位。此外, 考虑网络的中间层信息以扩大样本可用信息, 因为对于传统的深度学习技术, 中间层的大量信息总是被忽略。

1 系统框架

本文所提算法的定位框架如图 1 所示, 包含离线和在线两个阶段。在离线阶段, 首先就是采集来自 WiFi 接入点 (access points, APs) 的 RSSI 测量值, 以建立指纹数据库。假设在目标区域部署了若干个 APs 和 RPs, RPs 的位置被定义为:

$$\mathbf{L} = [(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)] \quad (1)$$

式中: N 为 RPs 的数量。在第 n 个 RP 处第 t 个时间戳采集到的 RSSI 数据可以表示为:

$$\mathbf{RSSI}_n^t = [rssi_{n,1}^t, rssi_{n,2}^t, \dots, rssi_{n,M}^t] \quad (2)$$

式中: M 为 APs 的数量。其次, 基于改进 CL 的数据处理

方法将指纹库中同一 RP 指纹之间的区分度缩小,同时将不同 RPs 指纹之间的区分度拉大,以提高指纹辨识力。再次,对获得的特征向量进行 z-score 标准化处理,以将不同量级的数据统一转化为同一个量级,从而保证数据之间的可比性。即:

$$\mathbf{FRZ}_m = \frac{\mathbf{FR}_m - \mathbf{v}_m}{\sigma_m} \quad m = 1, 2, \dots \quad (3)$$

式中: $\mathbf{FRZ}_m$ 和 $\mathbf{FR}_m$ 分别表示第 m 个处理前后的特征向量; $\mathbf{v}_m$ 和 σ_m 分别为平移因子和比例因子,即特征向量的均值和方差。

$$\mathbf{v}_m = \frac{1}{S} \sum_{i=1}^S fr_{i,m} \quad (4)$$

$$\sigma_m = \sqrt{\frac{1}{S} \sum_{i=1}^S (fr_{i,m} - \mathbf{v}_m)^2} \quad (5)$$

式中: $fr_{i,m}$ 为第 m 个特征向量的第 i 个元素; S 为单个特征向量的元素个数。然后将 CNN 和 LSTM 并行连接,并在池化层后添加 Flatten 层以构建特征融合网络模型。在线阶段,将目标点处采集到的指纹数据经过相同预处理后输入到训练好的特征融合网络模型中,从而解算出目标点的位置坐标。




图1 所提算法的框架

Fig. 1 Framework of the proposed algorithm

2 对比学习

2.1 改进的对比学习框架

由于 WiFi 信号极易受到动态环境的影响,因此即使在同一参考点采集的指纹数据也会存在较小的动态变化。当其动态变化的范围达到一定的程度时,可能会造成相邻参考点邻近区域指纹数据的模糊,即指纹辨识力降低,从而限制了定位精度的提高。传统的线性处理方法旨在寻找一个函数将指纹数据从原始空间映射到另一个维度空间。具体来说,对于输入向量 $\mathbf{X} = \{X_1, X_2, \dots, X_m\}$,寻找一个函数 $\mathcal{F}: \mathbf{X} \rightarrow \boldsymbol{\psi}$,其中 $\boldsymbol{\psi} = \{Y_1, Y_2, \dots, Y_n\}$ 表示输出向量。映射之后,具有相同标签的数据之间的差异缩小,而具有不同标签的数据之间的差异增大。然而,如上所述,这些线性和非线性方法存在一定的局限性。因此,为了更好地提高指纹辨识力,本文从学习的角

度对这些指纹进行编码。利用 CL 来学习编码器,其优点是不需要关注样本数据上繁琐的细节,只需要在对比损失特征空间学会对数据的区分即可,因此该模型以及其优化变得更加简单,更通用。

作为自监督学习的一种,CL 的核心思想是学习一个编码器,此编码器对同一类别的数据进行相似的编码,并使不同类别的数据的编码结果尽可能的不同。最初的对比框架主要由数据增强、编码器和投射头 3 个模块组成。与之前的框架相比,改进后的 CL 框架通过删除数据增强模块,增加数据过滤模块,从而避免数据增强繁琐的操作,降低了计算复杂度,达到了简化模型的目的。此外,数据筛选只需要将同类别的指纹作为正样本对,不同类别的指纹作为负样本对,简化了操作,方便了处理。

改进的 CL 框架如图 2 所示。其中,数据筛选模块用于确定每个批次的正负样本对;编码器模块用于提取指纹数据的表征向量;投射头模块用于将表征向量映射到对比损失空间,并通过对比损失函数来最大化相同类别样本之间的一致性。




图2 改进的对比学习框架

Fig. 2 Improved contrastive learning framework

1) 数据筛选模块

CL 的关键在于如何选择可靠的正负样本对。一般通过随机数据增强模块^[15]实现,即随机裁剪、随机颜色失真和随机高斯模糊。本文则使用一个数据筛选模块来确定正负样本对。其不需要数据扩充,只需要为每个批次筛选出正负样本,不仅简化了模型,还使优化过程更容易。由于 CL 的目标为最大化具有相同标签的指纹的相似性,并且最小化具有不同标签的指纹的相似性,因此将同一个 RP 的不同指纹作为正样本对,而将不同 RPs 的不同指纹作为负样本对。换句话说,将 $\mathbf{RSSI}_i^1$ 与 $\mathbf{RSSI}_i^2$ 作为一对正样本对,而将 $\mathbf{RSSI}_i^1$ 与 $\mathbf{RSSI}_j^3 (j \neq i)$ 作为负样本对。

2) 编码器模块 $f(\cdot)$

在编码模块中,合适的编码器至关重要,因为它直接关系到特征提取的性能。本文采用了一个简单的 CNN 网络以获取编码器。该网络可被视为一个非线性函数,即

$$\mathbf{h} = f(\mathbf{RSSI}_i^n) \quad (6)$$

式中: $\mathbf{h}$ 为神经网络的池化层输出。因此,编码后的指纹数据可以作为用于下游任务的矢量表示。

3) 投射头模块 $g(\cdot)$

编码后,利用包含一个隐藏层的多层感知机 (multilayer perceptron, MLP) 将编码器的输出转换到对比损失空间,即

$$\mathbf{z} = g(\mathbf{h}) = W^{(2)} \sigma(W^{(1)} \mathbf{h}) \quad (7)$$

式中: σ 为 ReLU 激活函数,被用于对比训练。

2.2 对比损失函数

为了量化对比损失空间中两个向量之间的相似性,这里选择余弦相似度作为度量标准,定义如下:

$$\text{similarity}(\boldsymbol{\alpha}, \boldsymbol{\beta}) = \frac{\boldsymbol{\alpha}^T \boldsymbol{\beta}}{\|\boldsymbol{\alpha}\| \|\boldsymbol{\beta}\|} \quad (8)$$

式中: $\boldsymbol{\alpha}$ 和 $\boldsymbol{\beta}$ 为向量空间中的两个向量; $\|\cdot\|$ 表示 ℓ_2 标准化。除此之外,本文将标准化温度标度交叉熵损失 (normalized temperature-scaled cross-entropy loss, NT-Xent)^[16] 作为对比损失函数。传统的交叉熵损失函数用于多分类任务,通过最小化真实标签和预测标签之间的差异来推动模型学习。然而,在计算相似性时,仅仅考虑正负样本之间的差异是不够的,还需要将同类样本彼此之间的差异考虑进来。标准化温度标度交叉熵损失函数是基于交叉熵损失函数的扩展,通过引入温度参数来调整分类标签的分布。这种方法能够使得同类样本之间的相似性更加突出,不同类别之间的差异更加明显。通过使用标准化温度标度交叉熵损失函数,模型可以更好地区分不同类别的样本,提高分类的准确性。给定一个指纹库,通过数据筛选模块随机选取 H 个样本对组成一个小批次,每个样本对包含两条指纹数据,即每个小批次包括 $2H$ 条指纹数据。通过随机选择任一样本对即两条指纹数据 $RSSI_i^1$ 与 $RSSI_i^2$ 作为正样本对,同时将剩下 $2(H-1)$ 条指纹数据作为负样本对。为了简化公式,将正样本对用 $\mathbf{R}_i$ 和 $\mathbf{R}_j$ 表示,而负样本对表示为 $\mathbf{R}_k$ 。然后,一对正样本对的对比损失函数可以定义为:

$$\ell(\mathbf{R}_i, \mathbf{R}_j) = -\log \frac{\exp\left(\frac{\text{similarity}(\mathbf{z}_i, \mathbf{z}_j)}{\tau}\right)}{\sum_{k=1}^{2H} \Gamma_{[k \neq i]} \exp\left(\frac{\text{similarity}(\mathbf{z}_i, \mathbf{z}_k)}{\tau}\right)} \quad (9)$$

式中: $\Gamma_{[k \neq i]}$ 是一个二值函数,当 $k \neq i$ 时,值为 1,否则为 0; τ 为温度参数。在一个小批次中,计算所有正样本对 $\mathbf{R}_i$ 与 $\mathbf{R}_j$ 的对比损失,包括 $\ell(\mathbf{R}_i, \mathbf{R}_j)$ 和 $\ell(\mathbf{R}_j, \mathbf{R}_i)$ 。然后求和作为最终的对比损失,即:

$$\text{loss} = \frac{1}{2H} \sum_{k=1}^H [\ell(\mathbf{R}_{2k-1}, \mathbf{R}_{2k}) + \ell(\mathbf{R}_{2k}, \mathbf{R}_{2k-1})] \quad (10)$$

算法 1 改进的对比学习算法

输入: 指纹库; 编码器模块 $f(\cdot)$; 投射头模块 $g(\cdot)$; 批次大小 H ; 温度参数 τ ;

输出: 编码器 $f(\cdot)$ 的输出;

```

for 小批次样本  $\{\mathbf{R}_{2k-1}, \mathbf{R}_{2k}\}_{k=1}^H$  do
    for  $k=1$  to  $H$  do
         $\mathbf{h}_{2k-1} = f(\mathbf{R}_{2k-1})$ 
         $\mathbf{z}_{2k-1} = g(\mathbf{h}_{2k-1})$ 
         $\mathbf{h}_{2k} = f(\mathbf{R}_{2k})$ 
         $\mathbf{z}_{2k} = g(\mathbf{h}_{2k})$ 
    end
    end
    for  $i=1$  to  $2H$  and  $j=1$  to  $2H$  do
        计算余弦相似度
         $\text{similarity}(\mathbf{z}_i, \mathbf{z}_j) = \mathbf{z}_i^T \mathbf{z}_j / (\|\mathbf{z}_i\| \|\mathbf{z}_j\|)$ 
    end
    计算样本对的损失函数  $\ell(\mathbf{R}_i, \mathbf{R}_j)$ 
    计算最终损失函数
     $\text{loss} = 1/2H \sum_{k=1}^H [\ell(\mathbf{R}_{2k-1}, \mathbf{R}_{2k}) + \ell(\mathbf{R}_{2k}, \mathbf{R}_{2k-1})]$ 
    更新  $f(\cdot)$  和  $g(\cdot)$  使得  $\text{loss}$  最小
end
return 编码器  $f(\cdot)$  的输出

```

3 PaCNN-LSTM 融合网络

3.1 卷积神经网络

相比一般的网络, CNN 具有局部连接和参数共享的特点, 其中局部连接避免信息丢失, 参数共享降低网络复杂度, 能更好地反映输入到输出的映射关系。CNN 模型分为特征提取和分类两个部分。其基本单元包括输入层、卷积层、激活层、池化层和全连接层。给定一个作为输入数据的多维数组 X 和一个包含 j 个基本单元的 CNN, 其第 H 个卷积层的输出如下:

$$f_H(X) = \sum_{i=1}^H (X^i * \omega_i + b_i) \quad (11)$$

式中: X^i 、 ω_i 、 b_i 分别表示输入数据、权重和偏差; $*$ 是卷积运算。经过其对应的激活层和池化层处理后, 卷积层的输出将被作为下一个基本单元的输入。通过这种方式, 样本数据的更深层次的特征将被迭代提取出来, 最后将提取到的特征送到全连接层。

3.2 长短期记忆

LSTM 模型主要利用前一个时刻的信息与现在时刻信息的关联性提取特征。与循环神经网络 (recurrent neural network, RNN) 不同的是, LSTM 会利用门控装置

对之前时刻的信息进行筛选,然后选择性的保存,降低了处理的复杂度,提高了学习效率。

LSTM 模型的基本单元包括遗忘门、记忆单元和输出门 3 部分,其可以由一个或多个基本单元组成。遗忘门决定了前一个基本单元将要遗忘的信息,由式 (12) 给出。

$$F_t = \sigma(\omega_f[h_{t-1}, X_t] + b_f)$$

(12)

式中: h_{t-1} 为前一个基本单元的输出; X_t 为隐藏层的输入; ω_f, b_f 分别表示权重和偏差; σ 为 sigmoid 函数。记忆单元决定了对应基本单元将要保存的信息,用于合并短期记忆 $\hat{C}_t$ 和来自遗忘门的长期记忆 I_t 。即

$$I_t = \sigma(\omega_i[h_{t-1}, X_t] + b_i)$$

(13)

$$\hat{C}_t = \tanh(\omega_c[h_{t-1}, X_t] + b_c)$$

(14)

$$C_t = F_t \cdot C_{t-1} + I_t \cdot \hat{C}_t$$

(15)

式中: ω_i, ω_c 为权重, b_i, b_c 为偏差; C_{t-1} 表示前一个基本单元的记忆单元输出。输出门决定了将要输出的部分信息,即:

$$O_t = \sigma(\omega_o[h_{t-1}, X_t] + b_o)$$

(16)

$$h_t = O_t \cdot \tanh(C_t)$$

(17)

式中: ω_o, b_o 分别表示权重和偏差。

3.3 PaCNN-LSTM 融合网络

深度学习模型所提取的信息对定位系统非常重要,因此本文提出了一种并行的融合网络,将 CNN 和 LSTM 并行结合,并在池化层后增加了 Flatten 层,以充分利用中间层的信息。PaCNN-LSTM 的框架如图 3 所示。CNN 网络由一个输入层、两个二维卷积层、两个可分离卷积层、两个最大池化层和两个 Flatten 层组成;LSTM 网络由一个输入层、一个 LSTM 层和一个 Flatten 层组成。该模型在每个池化层和 LSTM 层之后分别增加一个 Flatten 层,并将中间层的空间和时间特征考虑合并到全连接层。




图 3 融合网络架构

Fig. 3 Converged network architecture

表 1 为特征融合网络的具体信息。对于二维卷积层,其卷积核的尺寸设为 3×3 ,滤波器的数量为 32 个。对于深度可分离卷积层,其执行一个空间卷积,同时保持

通道独立,然后进行深度卷积操作。其次是学习如何以最佳方式将特征向量混合在一起的 64 个点卷积。整个可分离卷积核的尺寸设为 3×3 。每个卷积层后以最大池化层来减少学习参数的数量。LSTM 的隐藏层节点数设为 32,并且其与 CNN 的输入数据相同。每一层的输出都连接到全连接层。为了最小化损失函数,采用自适应估计(adaptive moment estimation, ADAM)训练网络的权重。通过迭代训练,直到损失函数小于所设置的阈值或者达到迭代次数,网络训练停止。

表 1 特征融合网络结构与参数

Table 1 Feature fusion network structure and parameters

层	滤波器数量	核大小	激活函数
二维卷积层	32	3×3	ReLU
二维卷积层	32	3×3	ReLU
最大池化层	—	2×2	—
Flatten 层	—	—	—
CNN			
二维可分离卷积层	64	3×3	ReLU
二维可分离卷积层	64	3×3	ReLU
最大池化层	—	2×2	—
Flatten 层	—	—	—
LSTM			
LSTM 层	32	—	tanh
Flatten 层	—	—	—
全连接层	参考点数量	—	Softmax

3.4 目标检测

在目标点处采集 RSSI 数据,然后利用构建的特征融合网络解算目标点的位置坐标。

4 实验结果及分析

为了评估所提定位算法在室内定位中的可行性,在重庆邮电大学第三教学楼 5 层设置实验场地来获取实验数据。收集数据时的现场情况如图 4 所示。通过在 $59.4 \text{ m} \times 12.9 \text{ m}$ 的实验场地进行实验,并划分了 3 个区域,包含房间和走廊两种环境。每个 RP 和 TP 处各采集 150 次数据。特征融合网络的搭建与训练测试都基于 python 语言实现的,其基本实验参数如表 2 所示。本文通过比较平均误差(mean)、标准差(STD)以及均方根误差(RMSE)来评估不同定位算法之间的性能差异。

4.1 基于对比学习的特征处理方法的性能

为了分析基于 CL 的特征处理方法,本文基于指纹数据库进行特征处理,并将其与两种常见的特征处理方法进行比较,即 PCA 和 ML。为了更好地评估上述特征处理方法对定位性能的影响,将特征处理后得到的表征向




图4 实验场地布局

Fig. 4 Layout of the experimental site

表2 实验参数
Table 2 Experiment parameters

参数	值	参数	值
训练批次	20	Dropout	0.5
迭代次数	80	训练数据	80%
优化器	Adam	测试数据	20%
学习率	0.001	温度参数 τ	0.3

量作为 CNN 模型的样本数据,在 3 个场地的定位性能比较结果如图 5 所示。从图 5(a)可以看出,相比未经过特征处理方法的定位性能,经过特征处理后方法的定位性能更好,说明特征处理方法的有效性。其次,从图 5(a)~(c)可以看出,在 3 个场地中,基于 CL 的特征处理方法的性能始终优于 PCA 和 ML,这意味着其可以很好地挖掘表征原始数据集的特征。除此之外,相比教室场景,在走廊场景中基于 CL 的特征处理方法的效果与之相差不大,但其他 3 种定位方法的性能明显下降,主要是因为走廊环境相对空旷,而且人流量更大,导致 RSSI 的波动更明显,说明所提方法更加稳健。

4.2 温度参数 τ 的影响

在损失函数中,温度参数 τ 在 CL 中具有重要作用,用最优温度参数训练的模型可以提高性能近 3%^[17]。由于用于训练模型的表示空间中的距离具有较小范数的梯度($\|\nabla \ell\| \propto 1/\tau$),较小的幅度梯度允许较大的学习率。




图5 不同特征处理方法的性能

Fig. 5 Performance of different feature processing methods

因此,恰当的温度参数使优化更容易,类更分离。3 个场地的不同温度参数 τ 的定位性能如表 3 所示。从表 3 可以看出,当 $\tau=0.3$ 时,3 个场地的平均定位误差分别为 0.72、0.80、0.63 m,标准差与均方根误差也较低,此时其

定位性能最好。随着温度参数 τ 逐步偏离 0.3,定位性能随之降低,尤其当 τ 增加到 0.5 及以上时,定位误差显著恶化。这一结果表明恰当的温度参数对模型性能具有较大的影响。

表3 不同温度参数 τ 的定位误差
Table 3 Positioning errors for different temperature parameters τ

	τ	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9
教室 1	Mean	1.32	0.93	0.72	0.93	1.19	1.36	1.42	1.64	1.91
	STD	0.69	0.74	0.31	0.28	0.61	0.61	0.72	0.63	0.55
	RMSE	1.49	1.18	0.78	0.97	1.33	1.49	1.59	1.75	1.98
教室 2	Mean	1.38	1.24	0.80	1.07	1.16	1.31	1.66	1.97	2.32
	STD	0.57	0.52	0.56	0.49	0.49	0.53	0.57	0.40	0.83
	RMSE	1.49	1.34	0.97	1.17	1.25	1.41	1.75	2.01	2.46
走廊	Mean	1.20	1.12	0.63	0.89	0.97	1.26	1.50	1.66	2.01
	STD	0.50	0.47	0.37	0.20	0.34	0.68	0.77	0.86	1.20
	RMSE	1.30	1.21	0.72	0.91	1.02	1.43	1.68	1.86	2.33

4.3 特征融合网络的性能

为了分析所构建特征融合网络模型的效果,这里比较了 4 种基于网络模型的定位方法,即 CNN、CNN+mid、CNN+LSTM 以及 PaCNN-LSTM 模型。图 6 所示为不同场景下 4 种网络模型的评估准确率与迭代次数之间的关系。评估准确率反映了模型在训练过程中正确预测的样本数占总样本数的比例,通过将整个数据集划分为训练集和测试

集,训练集用于模型训练,测试集用于模型评估以获得评估准确率。从图 6(a)可以看出,加入了中间层和 LSTM 的特征融合网络模型的训练效果最好,优于其他 3 种模型,例如其可以更快收敛,而且评估准确率更高,说明特征融合网络模型的有效性。其次,将整体而言,单独加入中间层和 LSTM 模型的性能优于单纯的 CNN 模型,而且走廊环境对训练出来模型的效果影响相对较大。




图 6 不同网络模型评估准确率与迭代次数的关系

Fig. 6 The relationship between the evaluation accuracy of different network models and the number of iterations

4 种定位方法的平均定位误差如图 7 所示。从图 7 可以看出,在 3 个场地中,相比其他 3 种定位方法,基于特征融合网络模型的定位方法的性能最好,其平均误差分别为 1.98、1.91、2.32 m,而单纯的 CNN 模型的平均误差分别为 2.71、3.14、4.75 m,提升比较显著。除此之外,相比单纯的 CNN 模型,分别加入中间层和 LSTM 的定位方法的性能也有一定的提升,说明中间层信息的可用性以及时间关联信息提取的有效性,这进一步验证了特征融合网络模型的有效性。同时走廊环境的定位性能相比教室有所降低,说明恶劣环境使得定位模型的鲁棒性下降。

当中,使得编码后的网络模型能够通过计算来进行验证。而对抗性攻击通过加入微小扰动再进行检测。但是其计算开销和计算时间太大,而且对于模型的结构有一些特定的要求。为了高效、快速评估所提出的融合网络模型的鲁棒性,本文基于网络模型的鲁棒性与该模型的倒数第 2 层的输出相关联的特性来预测其鲁棒性^[18]。也就是说,将需要进行鲁棒性评估的网络模型的倒数第 2 层神经元的输出作为新的网络模型的输入,然后输出用一些对抗性攻击的算法对网络模型进行计算的鲁棒性的值。4 种网络模型的鲁棒性比较结果如表 4 所示。平均鲁棒性的值是利用对抗性攻击算法 C&W 计算的测试集中样本的平均值。可以看出,相比其他 3 种网络模型,所提出的特征融合网络模型的鲁棒性最好,在原有的模型基础上有了一定的提升,其中教室环境下的鲁棒性更好。




图 7 不同环境下 4 种网络模型的定位误差

Fig. 7 Positioning errors of four network models in different environments

检验网络模型鲁棒性的方法主要有传统方法和对抗性攻击两种。传统的方法将网络模型编码到另一个模型

4.4 定位精度分析

为了比较所提算法与其他定位算法的性能,将提

表 4 不同网络模型的鲁棒性评估结果			
Table 4 Robustness evaluation results for different network models			
网络模型	平均 Robust		
	教室 1	教室 2	走廊
CNN	0.24	0.26	0.25
CNN+LSTM	0.27	0.25	0.25
CNN+mid	0.26	0.26	0.27
PaCNN-LSTM	0.31	0.32	0.28

出的算法命名为 PaCNN-LSTM+CL,并先后使用 K 邻近算法 (K-nearest neighbor, KNN) 和支持向量机算法 (support vector machine, SVM) 替换 PaCNN-LSTM,并与未经过特征处理的 3 种算法进行比较,结果如图 8 和表 5 所示。图 8 为定位误差的累积分布函数 (cumulative distribution function, CDF),表 5 反映了 6 种算法的定位误差。结果表明,随着定位误差的增加,这 3 种定位算

法的性能差异变得明显。例如 3 个场地中 3 m 内所提出的特征融合网络模型的定位误差分别在 81.0%、79.4%、68% 以内,高于其他两种经典的定位算法,分别为 73.6%、62.4%、40.7% 和 70.9%、65.0%、43.3%。与 KNN 和 SVM 相比,PaCNN-LSTM 具有更小的定位误差,这是由于神经网络可以挖掘样本数据更深层次的特征导致的。




图 8 不同定位算法定位误差的 CDF

Fig. 8 CDF of positioning errors for different positioning algorithms

表 5 不同定位算法的定位误差

Table 5 Positioning errors of different positioning algorithms			
定位算法	m		
定位算法	教室 1	教室 2	走廊
KNN	2.52	2.50	4.08
KNN+CL	1.20	1.35	1.28
SVM	2.77	2.35	3.56
SVM+CL	1.08	1.00	1.08
PaCNN-LSTM	1.98	1.91	2.31
PaCNN-LSTM+CL	0.59	0.79	0.82

经过特征处理和未经过特征处理的定位结果如图 8 所示。在未使用基于 CL 的特征处理方法的情况下,只使用原始指纹数据库作为训练样本,定位精度会有所降低,而 3 个场地中经过特征处理后的定位算法在 3 m 内的定位误差都在 95% 以内。为了更清楚地说明这一结果,由表 5 可知,当将基于 CL 的特征处理方法用于预处理时,3 种定位算法的平均定位误差有所下降,其中走廊环境下降最为明显。

5 结 论

本文首先提出了一种基于改进 CL 的数据处理方法,以获得能够更好地描述原始数据集的特征向量。然后,提出了一个基于 CNN 和 LSTM 的融合网络模型,以解决

单一神经网络模型在特征提取上的局限性。该模型通过融合输入样本数据的空间特征、中间层特征和时间特征,有利于提高定位模型的泛化能力。实验结果表明,本文提出的算法具有较好的定位精度和鲁棒性,显著优于其他经典算法。

参考文献

[1] LIU W, CHENG Q, DENG Z, et al. Survey on CSI-based indoor positioning systems and recent advances[C]. 2019 International Conference on Indoor Positioning and Indoor Navigation (IPIN). IEEE, 2019: 1-8.

[2] LI X, DENG Z, YANG F, et al. WiFi Indoor Location Method Based on RSSI[C]. 2021 11th IEEE International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Ap-plications (IDAACS). IEEE, 2021: 1036-1040.

[3] CAHYADI W A, CHUNG Y H, ADIONO T. Infrared indoor positioning using invisible beacon [C]. 2019 Eleventh International Conference on Ubiquitous and Future Networks (ICUFN). IEEE, 2019: 341-345.

[4] THIO V, APARICIO J, ÅNONSEN K B, et al. Experimental evaluation of the Forkbeard ultrasonic indoor positioning system [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 71: 1-13.

[5] YANG B, DAI C, YE H, et al. Research on high

- precision indoor positioning method based on low power bluetooth technology [C]. 2020 6th International Conference on Big Data and Information Analytics (BigDIA). IEEE, 2020: 133-137.
- [6] HAN Z, MINGXIA C, SHUNYAN L. Research on node location algorithm of Zigbee based on optimized neural network[C]. 2020 International Conference on Computer Engineering and Application (ICCEA). IEEE, 2020: 693-698.
- [7] SHATA A M, ABD EL-HAMID S S, HEIBA Y A, et al. Multi-site fusion for WLAN based indoor localization via maximum discrimination fingerprinting [C]. 2018 International Conference on Innovative Trends in Computer Engineering (ITCE). IEEE, 2018: 214-218.
- [8] WANG J, WANG X, PENG J, et al. Indoor fingerprinting localization based on fine-grained CSI using principal component analysis [C]. 2021 Twelfth International Conference on Ubiquitous and Future Networks (ICUFN). IEEE, 2021: 322-327.
- [9] LIU D, LIU Z, SONG Z. LDA-based CSI amplitude fingerprinting for device-free localization [C]. 2020 Chinese Control and Decision Conference (CCDC). IEEE, 2020.
- [10] LIAN L, XIA S, ZHANG S, et al. Improved Indoor positioning algorithm using KPCA and ELM[C]. 2019 11th International Conference on Wireless Communications and Signal Processing (WCSP). IEEE, 2019: 1-5.
- [11] SHEN G, HAN D, LIU P. A sparse manifold learning approach to robust indoor positioning based on WiFi RSS fingerprinting [J]. IEEE Access, 2019, 7: 130791-130803.
- [12] RAHMAN M, PRODHAN R, SHISHIR Y, et al. Analyzing and evaluating boosting-based CNN algorithms for image classification [C]. 2021 International Conference on Intelligent Technologies (CONIT). IEEE, 2021: 1-6.
- [13] WANG L, LUO H, WANG Q, et al. A hierarchical LSTM-based indoor geomagnetic localization algorithm[J]. IEEE Sensors Journal, 2021, 22(2): 1227-1237.
- [14] WANG R, LUO H, WANG Q, et al. A spatial-temporal positioning algorithm using residual network and LSTM[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(11): 9251-9261.
- [15] CHEN T, KORNBLITH S, NOROUZI M, et al. A simple framework for contrastive learning of visual representations [C]. Proceedings of Machine Learning Research, 2020: 1597-1607.
- [16] CHAKRABORTY S, GOSTHIPATY A R, PAUL S. G-SimCLR: Self-supervised contrastive learning with guided projection via pseudo labelling [C]. 2020 International Conference on Data Mining Workshops (ICDMW). IEEE, 2020: 912-916.
- [17] KHOSLA P, TETERWAK P, WANG C, et al. Supervised contrastive learning[J]. Advances in Neural Information Processing Systems, 2020, 33: 18661-18673.
- [18] WANG Y, LI Z, XU J, et al. Fast robustness prediction for deep neural network [C]. Proceedings of the 11th Asia-Pacific Symposium on Internetwork, 2019: 1-10.

作者简介



蒲巧林(通信作者),分别在2011年和2016年于重庆邮电大学获得学士学位和硕士学位,2022年于香港浸会大学获得博士学位,现为重庆邮电大学讲师,主要研究方向为无线定位与感知、普适计算与机器学习等。

E-mail: puql@cqupt.edu.cn

Pu Qiaolin (Corresponding author) received her B. Sc. degree and M. Sc. degree both from Chongqing University of Posts and Telecommunications in 2011 and 2016, and Ph. D. degree from Hong Kong Baptist University in 2022, respectively. She is currently an associated professor at Chongqing University of Posts and Telecommunications. Her main research interests include indoor localization, signal processing, and ubiquitous/pervasive computing.



陈有坤,2021年于南昌大学获得学士学位,现为重庆邮电大学硕士研究生,主要研究方向为室内WLAN定位和深度学习。

E-mail: ykc0923@163.com

Chen Youkun received his B. Sc. degree

from Nanchang University in 2021. He is currently a M. Sc. candidate at Chongqing University of Posts and Telecommunications. His main research interests include indoor wireless local area network (WLAN) localization and deep learning.



周牧, 分别在 2006 年、2008 年和 2012 年于哈尔滨工业大学获得学士学位、硕士学位和博士学位, 现为重庆邮电大学教授, 主要研究方向为无线定位与感知、量子精密测量、多源信息融合与机器学习等。

E-mail: zhoumu@cqupt.edu.cn

Zhou Mu received his B. Sc. degree, M. Sc. degree and Ph. D. degree all from Harbin Institute of Technology in 2006, 2008 and 2012, respectively. He is currently a professor at Chongqing University of Posts and Telecommunications. His main research interests include wireless localization and sensing, signal processing and detection, and machine learning and information fusion.



余征巍, 现为重庆邮电大学本科生, 主要研究方向为无线定位与感知。

E-mail: 17764013862@163.com

Yu Zhengwei is currently an undergraduate at Chongqing University of Posts and Telecommunications. His main research interest is wireless positioning and perception.



张钰坤, 2021 年于南昌大学获得学士学位, 现为重庆邮电大学硕士研究生, 主要研究方向为无线定位。

E-mail: s210131326@stu.cqupt.edu.cn

Zhang Yunkun received his B. Sc. degree from Nanchang University in 2021. He is currently a M. Sc. candidate at Chongqing University of Posts and Telecommunications. His main research interests include wireless positioning.