

基于 OCAE-SOM 的室内指纹定位算法研究

李新春¹, 纪小璐^{2*}, 魏武², 王黎彦², 谷永延², 曹大焱¹

¹ 辽宁工程技术大学电子与信息工程学院, 辽宁 葫芦岛 125105;

² 辽宁工程技术大学研究生院, 辽宁 葫芦岛 125105

摘要 针对室内定位技术精度较低及数据量过大影响运算时间等问题, 提出基于 OCAE-SOM (Optimized Convolutional Autoencoder-Self Organizing Map) 的室内指纹定位算法。离线阶段, 先将信道状态信息的幅值相位预处理矩阵作为原始输入数据, 并调整为 RGB (Red, Green, Blue) 格式训练卷积自编码器, 使其可深度挖掘参考点的指纹特征, 采用 Adam 算法优化 CAE 算法的参数, 既降低数据维度又能提升训练效率; 然后采用 OCAE-SOM 算法训练模型, 可以缩短单独训练模型的时间; 最后采用 Adam 算法优化 SOM 的权重, 可较好地保留输出特征间的相关性, 避免权重参数出现局部最优。在线阶段, 将调整后的测试数据输入到 OCAE-SOM 算法中, 经匹配后可得到输出位置点。实验结果表明, 该算法模型在定位时间与精度上显著优于已有算法, 具有一定的应用价值。

关键词 测量; 信道状态信息; 室内定位; 卷积自编码器; 自组织映射; Adam 算法

中图分类号 TN925+.93

文献标志码 A

doi: 10.3788/LOP202158.0812001

Research on Fingerprint Location Algorithm Based on OCAE-SOM

Li Xinchun¹, Ji Xiaolu^{2*}, Wei Wu², Wang Liyan², Gu Yongyan², Cao Dayan¹

¹ School of Electronic and Information Engineering, Liaoning Technical University, Huludao, Liaoning 125105, China;

² Graduate School, Liaoning Technical University, Huludao, Liaoning 125105, China

Abstract Aiming at the problems of low accuracy of indoor positioning technology and computational complexity, an indoor fingerprint location algorithm based on optimized convolutional autoencoder-self organizing map (OCAE-SOM) is proposed. In the offline stage, first, we use the amplitude and phase-preprocessing matrix of a channel state information as the original input data and adjust it to the RGB format to train the convolutional autoencoder (CAE) algorithm so that it can deeply mine the fingerprint features of a reference point. The Adam algorithm is employed to optimize the parameters of the CAE algorithm, which not only reduces the data dimension but also improves training efficiency. Then, we use the OCAE-SOM algorithm for model training. It can shorten the time to train the model separately. Finally, we use the Adam algorithm to optimize the weight of the self-organizing map, which can be better retain the correlation between output features to avoid the local optimization of weight parameters. In the online stage, the adjusted test data are input into the OCAE-SOM algorithm, and the output location point is obtained after matching. The experimental results show that the OCAE-SOM algorithm is significantly better than existing algorithms in terms of positioning time and accuracy, and it has certain application values.

Key words measurement; channel state information; indoor localization; convolutional autoencoder; self-organizing map; Adam algorithm

OCIS codes 120.7000; 120.5050; 100.4996; 150.1135

收稿日期: 2020-08-04; 修回日期: 2020-09-06; 录用日期: 2020-09-09

基金项目: 国家自然科学基金(61372058)

* E-mail: 3078929795@qq.com

1 引言

随着室内定位技术的发展,基于无线局域网(Wireless Local Area Networks, WLAN)的指纹定位技术因具有低成本和高普适性等优点而成为室内定位技术的研究热点之一^[1],指纹定位是根据物理位置点与其指纹信息的唯一对应来实现的。基于 WLAN 的指纹定位技术中,基于接收信号强度(Received Signal Strength, RSS)^[2]的定位方式较为普遍,但因其存在稳定性差、定位精度较低以及易受多径效应影响^[3-4]等问题,科研人员将目光开始转向基于信道状态信息(Channel State Information, CSI)的室内指纹定位算法,使用 CSI 定位指纹信息具有时间稳定、频率多样和数据稳定等优势,可更完整地反映定位环境中的多径效应,故基于 CSI 的室内指纹定位算法更能体现数据的细粒程度^[5],更适合开展室内指纹定位的研究。基于 CSI 的室内指纹定位算法包括离线构建指纹库和在线匹配两个阶段^[6]。离线阶段主要完成 CSI 数据的采集,根据实验环境合理地设置参考点(Reference Point, RP)和数据采集接入点(Access Point, AP)的位置,并采集各 RP 的信道状态信息以建立指纹库;在线阶段旨在匹配测试点(Test Point, TP)的 CSI 指纹与指纹库中的指纹信息,进而输出定位结果。

目前,CSI 成为室内定位技术的研究热点之一,基于 CSI 的室内指纹定位算法的研究,诸多学者提出了不少新的研究算法。为了提高定位精度,文献[7]提出了将 RSS 和 CSI 结合的二阶段室内指纹定位方法,利用核函数和改进的 K 最近邻(K -Nearest Neighbor, KNN)算法进行指纹库的构建和精确位置的估计,但建立指纹库的过程中并未考虑 CSI 数据的相位信息。文献[8]为避免单一指纹数据所造成的精度低和稳定性差等问题,将 CSI 的幅度与相位结合以构建指纹库,使用支持向量机(Support Vector Machines, SVM)在室内指纹定位的过程中进行数据学习和分类,但 SVM 属于浅层网络,其特征提取与关系拟合能力有限,为此限制了定位精度的提升空间,且未考虑数据特征的提取效率及定位时间。文献[9]使用了随机森林(Random Forest, RF)模型训练由 4 个路由器收集到的 CSI,并将其作为指纹信息以减少多径效应,最终解决了 CSI 室内指纹定位技术的信息采集及指纹存储任务重的问题,但所用路由器的个数较多,不符合大多数办公室的实际情况。文

献[10]在离线阶段将 CSI 的幅度与相位进行线性变化处理,预处理后建立指纹库,在线阶段采用改进的加权 KNN 算法在室内指纹定位的过程中对坐标进行二次匹配,但特征提取的过程中未考虑数据量过大而影响系统的定位时长,所以只能满足基本的定位要求。文献[11]利用了预处理后的 CSI 的幅值与相位作为室内定位的指纹信息,并将 SVM 与极限梯度提升(XGBoost)算法应用在指纹库的高精度构建上,在线阶段结合机器学习算法与指纹库匹配实时的指纹信息,可以达到 90% 以上的定位精度,但在指纹库的构建过程中,该算法不能较好地捕捉指纹特征之间复杂的非线性关系,从而影响定位精度。

针对上述存在的问题,本文提出基于 OCAE-SOM(Optimized Convolutional Autoencoder-Self Organizing Map)的室内指纹定位算法,依据文献[12]将 CSI 数据调整为类似图像 RGB(Red, Green, Blue)格式的数据形式,旨在分析每个参考点的 CSI 数据在时间维度、子载波维度和天线维度上关于幅度和相位的细粒度特征。离线阶段,将采集的原始 CSI 数据经过数据提取和格式转换处理后输入卷积自编码器(Convolutional Autoencoder, CAE)中,对指纹特征进行深度挖掘提取以避免忽略非线性的数据特征,再利用全连接层将 CAE 的瓶颈层输出作为自组织映射(Self-organizing Map, SOM)算法的输入,将数据特征按参考点的数目进行分类并与物理位置相对应,从而完成指纹库的构建,采用 Adam 算法优化更新算法的参数和权重,以减少在线阶段匹配的计算量,从而提升自适应学习率,保证定位效率与精度。在线阶段,将测试点数据进行幅度和相位预处理后,输入模型可直接匹配输出物理位置信息。

2 相关理论

2.1 CSI

CSI 是基于正交频分复用-多人多出(Orthogonal Frequency Division Multiplexing-Multiple-Input Multiple-Output, OFDM-MIMO)技术的无线网卡从物理层获取系统频带内子载波粒度的信道响应^[13],将其作为一种数据格式来表示各子载波上发送端和接收端之间的信道属性。依据文献[14]可知,因 802.11n 协议支持在信号传输的发射端和接收端分别使用多个发射天线和接收天线的 MIMO 技术,故每个 CSI 测量值可以表示为

$$C = \begin{bmatrix} C_{1,1} & \cdots & C_{1,T} \\ \vdots & & \vdots \\ C_{R,1} & \cdots & C_{R,T} \end{bmatrix}, \quad (1)$$

式中： T 和 R 分别表示发射天线和接收天线的数量，则单个 CSI 测量值在天线维度上的长度 $d = T \times R$ 。因 CSI 属于子载波级别的信道复数测量值，故在某个天线上包含了频域中每个子载波的幅度与相位值，可表示为 $C = \{c_{TR,n}\}$ ，其中 $n = 1, 2, \dots, N_{\text{sub}}$ ，其中 N_{sub} 表示子载波的个数，值为 30， $c_{TR,n}$ 为第 n 个子载波的信道频率响应，可表示为

$$c_{TR,n} = r_{c_{TR,n}} \exp(jp_{c_{TR,n}}), \quad (2)$$

式中： $r_{c_{TR,n}}$ 和 $p_{c_{TR,n}}$ 分别表示第 T 条发射天线与第 R 条接收天线所组成的信道上，第 n 个子载波的幅度响应和相位响应。

2.2 相位与幅值的预处理

由 2.1 节的 CSI 表示形式可以获取所有位置的幅度与相位并用作指纹信息，但忽略了原始数据在子载波维度与天线维度上的信息，所以在建立指纹库前总是将相同天线上 30 个不同子载波的幅值求平均，或不同天线上相同子载波序号的幅值取中值作为该位置的代表值，这不仅影响定位精度，还会模糊原有特征。为了避免主观因素的影响，将保留所有天线维度与子载波维度的幅值信息，只将所有异常幅值利用均值替换的方式进行去除再进行特征提取，不仅能够最大程度地保留该位置的幅值信息，还可以优化定位精度。

为了避免指纹信息的单一化，除了幅值以外，相位也将作为 CSI 室内指纹定位的一种重要指纹信息。相对于幅值信息，相位信息更为敏感，因其受到残余同步误差会发生较大偏移，故原始相位存在相位跳变和偏移，所以不能直接将原始相位作为指纹信息，需先对相位进行解卷绕处理，再参考文献[15]进行线性变换以消除未知的时漂引起的相位误差和相位补偿，使其不再包含环境噪声，具有更稳定的分布，最终可得到真实且有利用价值的相位信息，并将其与预处理后的幅值共同作为指纹信息以提取特征。

3 基于 OCAE-SOM 的室内指纹定位算法

3.1 基于 CAE 的指纹特征提取

在室内指纹定位的研究过程中，指纹数据特征的提取方法是影响定位系统性能的主要因素之一。本节从特征提取方法入手，采用一种无监督学习方

法，即使用卷积自编码器挖掘出预处理后的 CSI 的幅值与相位数据中隐含的非线性特征，并使用低维矩阵来表示输入数据的特征。CAE 中的卷积操作不仅可以提取隐藏在数据中难以发现的空间特征，还可以保留原始输入数据在抽象空间中的关系，而且卷积核的局部连接与共享权值特性可大大降低网络模型的参数规模，使 CAE 在较短的训练时间内达到较优的特征提取效果，从而减少特征数据的损失，尤其在处理图像格式方面具有较好的应用效果。CAE 主要由编码器和解码器组成。编码器主要对输入数据进行卷积操作以获得低维特征表示并将其映射到瓶颈层，可以在减小原输入数据尺寸的同时获取原数据的隐藏特征。解码器是一个与编码器相反的过程，将压缩数据重建得到与原始输入数据相同维度的输出数据，输入数据与输出数据间的差异尽量最小化^[16]。

CAE 的基本结构如图 1 所示。当输入数据进入卷积层时，卷积核按照指定的步长与调整后的输入数据进行卷积运算以提取数据特征，并将其映射于池化层^[16]。设第 l 层中第 i 个特征映射为

$$\theta_i^l = \sigma \left(\sum_{m \in S_{l-1}} \omega_{im}^l * \theta_m^{l-1} + b_i^l \right), \quad (3)$$

式中： ω_i^l 表示在第 l 层中生成第 i 个特征映射的卷积核，且相邻神经元的活性相似，虽 m 值不同，但其可共享相同的权值参数； b_i^l 表示偏置参数； S_{l-1} 表示在 $l-1$ 层中与当前特征映射连接的所有特征映射的集合； σ 表示激活函数，作用是引入非线性因素以避免获得由输入数据组成的简单线性组合，从而提升 CAE 的特征表达能力； $*$ 表示二维卷积运算。因修正线性单元 (Rectified Linear Unit, ReLU) 是应用最广泛的一种激活函数，具有可稀疏激活、快速

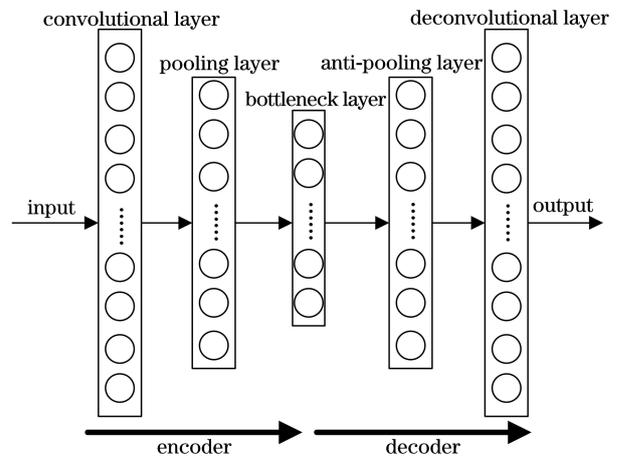


图 1 卷积自编码器的基本模型

Fig. 1 Basic model of convolutional autoencoders

收敛和求解梯度简单的优点,所以 CAE 的网络模型中的各层都采用 ReLU 函数作为激活函数以降低梯度消失的可能性^[17]。ReLU 的表达式为

$$f(x) = \max(0, x)。(4)$$

因多个不同尺寸的卷积核可提取出输入数据中多个具有差异的特征,故在该网络的编码器部分设

表 1 CAE 的网络结构

Table 1 Network structure of CAE

Layer	Parameter	Activation function	Output size
Convolutional layer	3×3 filter kernel 16 feature images	ReLU	64×64×16
Max pooling layer	2×2	-	32×32×16
Convolutional layer	3×3 filter kernel 8 feature images	ReLU	32×32×8
Max pooling layer	2×2	-	16×16×8
Convolutional layer	3×3 filter kernel 8 feature images	ReLU	16×16×8
Max pooling layer	2×2	-	8×8×8

每个卷积层后都连接一个最大池化层,即选择池化窗口中的最大值并将其作为池化层的输出^[18]以减小数据维度。输入数据经过三个卷积层和池化层后,编码器将其压缩输出至瓶颈层以便于映射,输入数据的特征维度经过编码器后被压缩至 8×8×8,实现降维与特征提取。假设 \mathbf{P} 为输入矩阵,则编码器在瓶颈层中对输入数据的压缩表达式为

$$e_i = \sigma'(\mathbf{P} * F^k + b_e), (5)$$

式中: σ' 表示非线性激活函数; F^k 表示编码器中第 k 个卷积核的权重; b_e 表示编码器的偏置。由解码器解码后的重构数据 z_i 可表示为

$$z_i = \sigma'(e_i * \tilde{F}^k + \tilde{b}_e), (6)$$

式中: \tilde{F}^k 表示解码器中第 k 个卷积核的权重; \tilde{b}_e 表示解码器的偏置。将原始 CSI 值调整为图像格式后进行归一化处理,再输入 CAE 模型中进行学习并获取特征映射。

在模型的训练学习过程中,为了完善 CAE 重构数据的性能,使用均方误差损失函数作为衡量重构误差的一个指标。损失函数^[19]的表达式为

$$\min_{\theta} J(\theta_a) = \frac{1}{M} \sum_{m=1}^M \|\hat{\mathbf{x}}^{(m)} - \mathbf{x}^{(m)}\|_2^2 + \beta \sum_{v=1}^V x_{\text{KL}}[\rho \|\bar{X}(v)\|] + \lambda R(\theta_a), (7)$$

式中: λ 表示惩罚因子; β 表示稀疏比例系数,在训练网络的过程中,不断调整 CAE 参数使其达到最

置三个卷积层,如表 1 所示。从表 1 可以看到,每个卷积层都包含尺寸为 3×3 的卷积核,并且各层卷积核的数量分别为 16、8 和 8。解码过程是一个与编码过程呈镜面对称且顺序相反的过程,由参数数量相同的反卷积层与反池化层组成,且参数与编码过程的参数互置,在此主要详解编码过程。

小值; θ_a 表示自变量参数; J 表示目标函数; M 表示输入数据向量样本的个数; V 表示给定的训练样本个数; x_{KL} 表示 KL(Kullback-Leibler)散度; ρ 表示事先设定的较小值,表示神经元被激活的概率; \bar{X} 表示在隐藏编码中第 v 个神经元的平均激活值,近似为第 v 个神经元被激活的概率; λ 表示惩罚因子,即正则化参数; R 表示正则化项; $\hat{\mathbf{x}}$ 表示重构后的数据向量; \mathbf{x} 表示重构前的数据向量。等式右侧依次为重构损失项、KL 散度项和惩罚项。重构损失项用来衡量原始输入与重构结果之间的差异;KL 散度项用来衡量重构数据比原始数据丢失的信息量;惩罚项用来降低极小变量对编码器的影响,从而辅助编码器学习特征,防止过拟合, λ 可控制正则化强度,经典值设为 0.01,惩罚项可通过求解 L_2 范数得到。在模型完成输入数据的重构后,将瓶颈层的压缩输出作为 CSI 指纹特征,用于后续模型的学习训练与定位。

3.2 基于 SOM 神经网络的分类判别

3.1 节虽使用 CAE 提取出由预处理后的 CSI 的幅值与相位组成的联合指纹特征映射,但特征较多,无法准确与各自代表的物理位置点相对应,为此将 SOM 神经网络作为一种无监督竞争式学习的前馈网络,并在学习训练数据的过程中进行自组织学习^[20-21],从而完成指纹特征的分类与判别。SOM 神经网络的聚类算法比其他非神经网络具有更高的鲁

棒性,可以将高维数据的输入映射为低维数据的输出以保持其拓扑结构,而且其特征相似性不因网络映射而改变。使用 SOM 提取输入数据的潜在特征及规律并进行分类,使指纹特征与物理位置相对应。SOM 包含输入层和竞争层,设输入层的神经元数为 p ,竞争层为由 q 个神经元组成的二维平面阵列,竞争层使用尺寸为 14×7 的二维平面阵列来表示参考点排列位置的分布,而且网络是全连接的,即每个输入结点都与所有的输出结点相连接。

设从 CAE 瓶颈层中输出 s 维向量 $\mathbf{X} = [X_1 X_2 \cdots X_s]$,并将其作为 SOM 网络的输入。在 SOM 网络竞争层中建立一个有 s 个输出节点的二维网络,其中第 p 个输入神经元节点与第 q 个输出神经元节点之间的连接权值为 w_{pq} ,具体实现分类的过程如下。

1) 将连接权值随机初始化为 $1/p$,设置一个较大的初始邻域 σ_0 ,其能够包含所有神经元。以一定的概率从样本输入空间中输入 s 维向量 $\mathbf{X} = [X_1 X_2 \cdots X_s]$,表示应用于网络的激活模式。

2) 计算 t 时刻输入神经元和所有输出神经元的欧氏距离^[21],表达式为

$$d_q = \sum_{p=1}^P [x_p(t) - w_{pq}(t)]^2. \quad (8)$$

依据

$$x_p - w_{pq} = \min(d_{pq}) \quad (9)$$

来选择与 x_p 距离最小的神经元 $c(x)$,则 $c(x)$ 即为获胜的神经元。

3) 根据

$$w_{pq}(t+1) = w_{pq}(t) + \eta(t)h_{q,c(x)}(t) \times [x_p(t) - w_{pq}(t)] \quad (10)$$

来更新结点 $c(x)$ 及其邻域结点的连接权值。式中: $\eta(t)$ 表示增益函数, $0 < \eta(t) < 1$,随着 t 值的增加逐渐趋于零,因此学习过程是收敛的; $h_{q,c(x)}(t)$ 表示获胜神经元周围的邻域函数,实验采用高斯函数,可表示为

$$h_{q,c(x)} = \exp \left[-\frac{\|\mathbf{r}_{c(x)} - \mathbf{r}_q\|}{2\sigma^2(t)} \right], \quad (11)$$

其中领域范围可表示为

$$\sigma(t) = \sigma_0 \exp(-t/\tau_0), \quad (12)$$

式中: \mathbf{r}_q 和 $\mathbf{r}_{c(x)}$ 分别表示输出节点 q 和 $c(x)$ 的位置; τ_0 为时间常数,用于调整下降速度。

4) 选取另一组学习样本提供给网络的输入层并返回步骤 1),但无需再次初始化参数,可以将其输入到输入层,直到输入样本全部提供给网络即可。

5) 令 $t=t+1$,返回步骤 2),直至所有样本学习完为止。

3.3 Adam 优化算法

Adam 优化算法^[22]不仅较 AdaGrad 和 RMSProp 两种常见的优化算法更宜处理大量的高维数据,而且能够优化稀疏梯度和非平稳目标的自适应学习率^[23]。因 CAE 模型在构建的过程中,需要最大程度地最小化输入与输出之间的误差,所以采用 Adam 优化算法优化模型参数,可以提高 CAE 特征提取的能力。SOM 算法在更新和优化权值的过程中容易产生局部最优而影响权值大小和分类精度,故也采用 Adam 算法对权值进行优化和更新。参数设置如表 2 所示,优化过程如下。

表 2 Adam 算法的参数设置

Table 2 Parameter setting of Adam algorithm

Parameter	Meaning	Value
α	Learning rate	0.01
β_1	Exponential decay rate of 1 st moment estimate	0.9
β_2	Exponential decay rate of 2 nd moment estimate	0.999
ϵ	Constant	1×10^{-8}

β_1 和 β_2 的取值范围为 $[0,1)$ 。若设 θ_a 为初始参数,则一阶矩和二阶矩分别初始化为零矩阵 \mathbf{m}_0 和 \mathbf{n}_0 ,优化的目标函数 f^* ^[22]可表示为

$$f^* = \|\mathbf{R} - \tilde{\mathbf{R}}\|^2, \quad (13)$$

式中: \mathbf{R} 表示定位目标的实测原始数据; $\tilde{\mathbf{R}}$ 表示优化模型估计的数据。在优化 CAE 模型的过程中,(5)式与(6)式中的因变量分别代表 \mathbf{R} 与 $\tilde{\mathbf{R}}$,自变量为模型参数。在 SOM 优化权值的过程中,目标函数为(10)式中的连接权值差,即 $w_{pq}(t+1) - w_{pq}(t)$,自变量为 t 。详细计算过程如下。

1) 先计算样本的梯度,表达式为

$$\mathbf{g}_t = \nabla_{\theta_a} f_t^*(\theta_{a,t-1}), \quad (14)$$

式中: \mathbf{g}_t 表示关于 t 的随机目标函数 f^* 的梯度; $\theta_{a,t-1}$ 表示时间步长为 $t-1$ 的决策变量; ∇_{θ_a} 表示对变量 θ_a 的函数 f^* 求梯度。

2) 更新有偏一阶矩估计 \mathbf{m}_t 和有偏二阶矩估计 \mathbf{v}_t ,表达式为

$$\mathbf{m}_t = \beta_1 \cdot \mathbf{m}_{t-1} + (1 - \beta_1) \mathbf{g}_t, \quad (15)$$

$$\mathbf{v}_t = \beta_2 \cdot \mathbf{v}_{t-1} + (1 - \beta_2) \mathbf{g}_t^2. \quad (16)$$

3) 修正一阶矩的偏差和二阶矩的偏差,表达式为

$$\hat{m}_t = \frac{m_t}{(1 - \beta_1^t)}, \quad (17)$$

$$\hat{v}_t = \frac{v_t}{(1 - \beta_2^t)}. \quad (18)$$

4) 应用更新量 $\theta_{a,t}$, 可表示为

$$\theta_{a,t} = \theta_{a,t-1} - \alpha \frac{\hat{m}_t}{(\sqrt{\hat{v}_t} + \epsilon)}. \quad (19)$$

3.4 基于 OCAE-SOM 的室内定位算法

为了减少数据运算量以及提高定位效率, 提出一种降维与分类过程相结合的无标签定位法, 即

SOM 算法, 又因数据特征提取的优劣会影响定位精度且 SOM 算法易受缺省值的影响, 提出结合优化后的 CAE 特征提取算法和改进的 SOM 指纹特征分类算法, 即 OCAE-SOM 算法。采用该算法后, 不仅在室内指纹定位的两个阶段中提升了运行效率, 还可以保证整个定位过程的精度。在线阶段, 将测试数据的 CSI 的幅值与相位预处理后作为该网络模型的输入, 可以较快匹配并输出物理位置的坐标点, 从而实现高精度定位。整体算法的流程如图 2 所示。

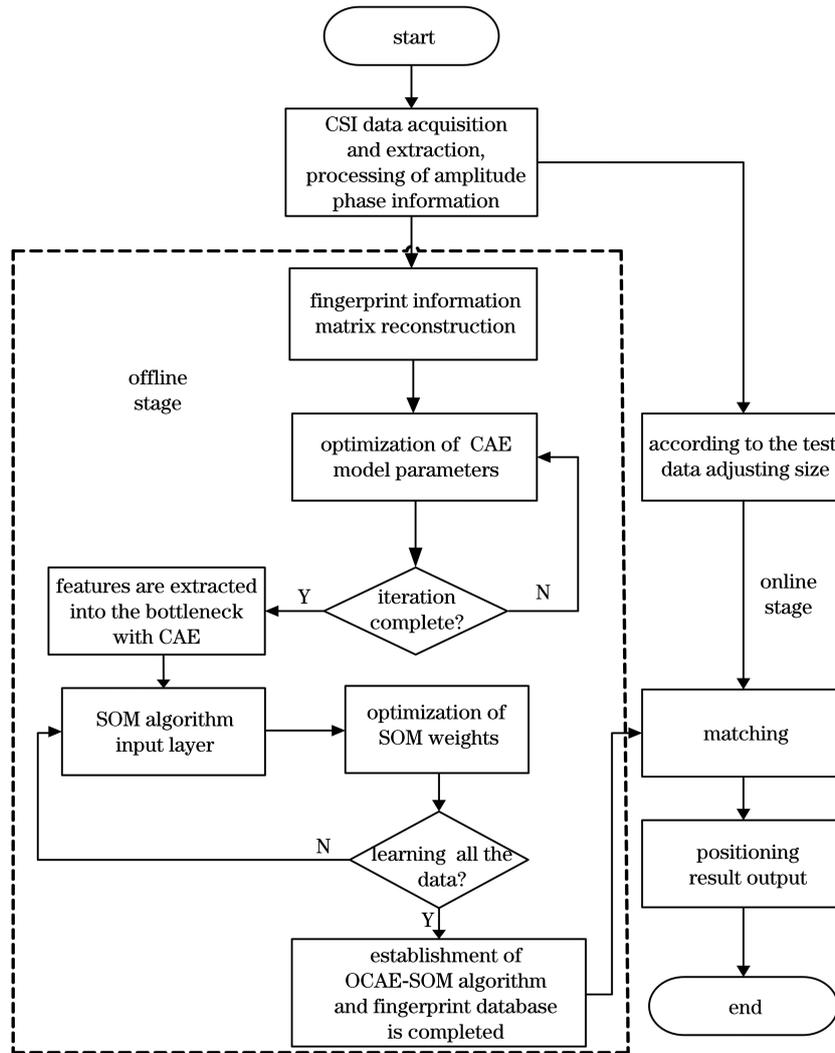


图 2 整体算法的流程

Fig. 2 Flow chart of overall algorithm

从图 2 可以看到, 模型的输入数据为各个参考点的原始 CSI 图像, 每个样本的尺寸为 $N_t \times N_{sub} \times N_a$, 其中三个维度的长度分别对应于 CSI 在时间、子载波以及天线维度的数量, 输出数据即为该参考点的物理位置。优化完成后, 将卷积特征的提取结果映射在 SOM 输入层上, 将卷积自编码器中瓶颈

层的输出作为 SOM 神经网络的输入并对其进行训练, 将训练后的编码网络模型参数设置于此。

OCAE-SOM 算法通过将原本两个独立训练的模块(基于 CAE 的指纹特征提取与基于改进的 SOM 的指纹分类)整合为单个网络模型, 实现从输入原始 CSI 数据到输出位置坐标的指纹定位, 降低

了原本训练过程由多个模块组成整个定位算法系统的复杂程度。此外,若分别训练特征提取和分类两个模块,则会较大程度地破坏原本特征的良好卷积表示,而 OCAE-SOM 作为完整的网络模型,将原始数据的卷积表示映射在输入层上作为 SOM 的输入,可以较好地保留输出特征元素间的相关性。

4 实验分析

4.1 实验环境的搭建

为了验证所提算法的定位效果,实验场所的选取考虑了理想的无线传播环境(Light of Sight, LOS)和实际的复杂无线传播环境(Non Light of Sight, NLOS)两种情况。LOS 选择辽宁工程技术

大学新实验楼西 301 室,面积约为 139 m^2 ,其中除了实验器材外只有一个测试人员,无其他干扰因素,地砖尺寸为 $60 \text{ cm} \times 60 \text{ cm}$ 。为了避免参考点过于密集,实验将测试点的间隔选为 90 cm 且呈正方形分布,参考点的分布与 AP 的位置如图 3(a)所示,共 98 个参考点(圆点表示),45 个测试点(五角星表示),测试过程中 AP 的位置始终不变。NLOS 选择辽宁工程技术大学新实验楼东 302 室,该环境内包括了部分通信类实验器材、桌椅柜子、手机和计算机,干扰因素较多,选择 60 个参考点和 30 个测试点,测试间隔为 180 cm ,测试过程中 AP 的位置不变,分布如图 3(b)所示。两种实验场所的数据具有一定的差异性和代表性。

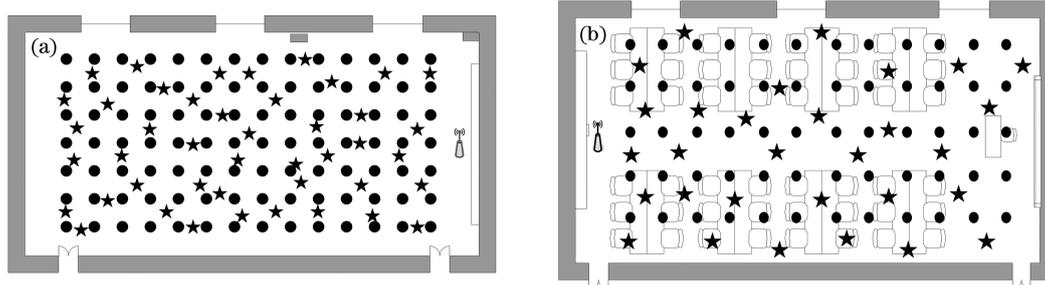


图 3 不同的环境布局。(a)LOS 布局;(b)NLOS 布局

Fig. 3 Different environment layouts. (a) LOS layout; (b) NLOS layout

数据采集过程中,使用一台四天线的频率为 2.4 GHz 和 5.0 GHz 兼容的 TP-Link 路由器作为发射端,接收端使用运行版本为 10.04 LTS 且系统为 32 bit Ubuntu Linux 的计算机,通过计算机中的三天线 Intel 5300 半高内置网卡来获取由路由器转发的 CSI 信号。每个待测点测试两次,以每秒采集 50 次的采集频率采集 30 s ,则每个点可采集到 2000 个数据包,每个数据包中又可获得 180 维原始的 CSI 数据。参照图 3 逐一按序采集 RP 的 CSI,使各个 RP 的物理位置信息与人为坐标位置信息一一对应,利用 CSI 的幅值和相位组成每个 RP 的指纹信息并存储在特征矩阵中以便进行数据处理,接着测量测试点 CSI,预处理后输入模型中得到测试点坐标,并将其与实际坐标位置进行比较以判断算法的优劣。

4.2 数据尺寸对模型的影响

当使用 CAE 提取特征时,不同的输入数据尺寸会影响特征提取的效果^[24]。为了使 CAE 模型能够获得较优的重构数据,通过对比三种不同输入数据尺寸下的损失曲线来确定最优的尺寸。原始的 CSI 训练样本数据在子载波维度的长度为 30,天线维度为 3,则 CSI 特征图的尺寸为 $N_t \times 30 \times 3$ 。数

据采集过程中,每个样本点采集 2000 条数据,当样本总量相同时,不同的连续帧数可构造出不同的特征图像。

为了构造最有效的特征图像,将调整 CSI 特征图的维度,因帧数过短或过长都会影响特征图像构造的有效性,这有可能会造成模型过拟合。将特征图调整为类似于三通道的图像数据,通过对训练样本尺寸进行形变与缩放,可将其行列的长度分别调整为 16×16 、 32×32 和 64×64 ,并用来训练在 NLOS 布局下采用 Adam 算法优化后的 CAE 算法模型,其损失函数对比曲线如图 4 所示。从图 4 可

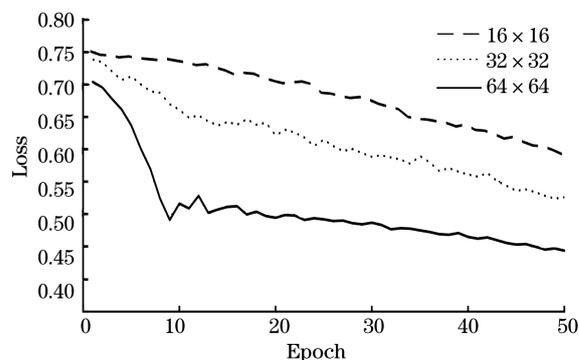


图 4 不同尺寸的损失对比曲线

Fig. 4 Loss comparison curves of different sizes

以看到,在 NLOS 布局中,当训练样本的输入尺寸分别为 16×16 、 32×32 和 64×64 时,每个模型输出的损失值都随着训练次数的增加整体呈下降趋势,其中当尺寸为 64×64 时,任何时期的损失值都相对最小,且能够最快下降到相对稳定的损失值,所以当输入数据的尺寸为 $64 \times 64 \times 3$ 时,模型重构的效果最优,且 CAE 网络模型可较快收敛。

4.3 特征提取方法对模型的影响

不同的特征提取方法之间存在差异性,这会导致从同一原始数据提取出的数据特征也有所不同,从而

直接影响指纹库的构建,间接影响在线阶段的定位精度。为了验证 CAE 模型在特征提取方面的优势,本节指纹匹配方式均采用 SOM 算法来保证实验的合理性。在此选取传统的特征提取方式统计平均与主成分分析(Principal Component Analysis, PCA)方法,并与所提算法在输入相同的前提下并在 LOS 布局与 NLOS 布局中进行比较。为了评价卷积自编码器在重构 CSI 指纹以及提取特征方面的优势,在平均定位误差、训练时间和最大定位误差三个方面进行比较,结果如表 3 所示。

表 3 特征提取方法的定位精度对比

Table 3 Comparison of location accuracy of feature extraction methods

Method	Environment	Maximum positioning error /m	Average positioning error /m	Training time /s
CAE	LOS	4.5382	1.2725	3.41
	NLOS	7.9603	1.9341	6.32
PCA	LOS	6.0362	1.7260	7.29
	NLOS	9.5374	2.3071	12.53
Statistical average	LOS	6.5607	1.9564	9.72
	NLOS	10.6243	3.0472	16.74

从表 3 可以看到,相比于 PCA 与统计平均两种方式,CAE 算法模型具有较明显的定位优势,在两种实验环境中不仅平均定位误差与最大定位误差均明显低于其余两种方式,而且训练时间分别提高了 3.88 s 和 6.31 s,在复杂环境中又分别提升了 6.21 s 和 10.42 s。通过对比分析可知,CAE 算法模型对于学习与提取 CSI 数据特征具有较优的拟合效果。

4.4 优化方式对算法模型的影响

因为 CAE 参数与 SOM 权重的更新需要快速且最优,故优化参数与权值可以保证整个算法模型体系更精确,具有更优的性能,在此比较 4 种较为典型的优化方式在所提算法模型中的优化效果并确定最好的优化方式。通过比较 4 种方式在复杂环境下模型优化的正确率来衡量优化算法的优越性,结果如图 5 所示。

从图 5 可以看到,Adam、SGD、RMSProp 和 AdadeIta 4 种方式优化算法模型的正确率分别可达

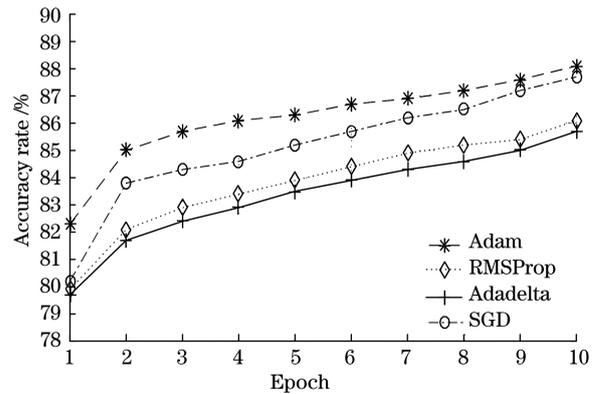


图 5 不同方式下的正确率对比曲线

Fig. 5 Contrastive curves of accuracy in different modes to 88.1%、87.7%、86.1%和 85.7%;在整个过程中,Adam 优化算法的正确率明显高于其他三种经典优化算法,且在遍历次数为 1 的情况下正确率也优于其他优化方式,其对于所提算法模型的优化效果如表 4 所示。从表 4 可以看到,定位误差在 1 m

表 4 所提算法改进前后的性能对比

Table 4 Performance comparison of proposed algorithm before and after improvement

Algorithm	Probability distributions /%		Training time /s
	Accumulate within 1 m	Accumulate within 2 m	
CAE-SOM	62.71	85.36	10.42
OCAE-SOM	70.54	96.11	1.86

以内和 2 m 以内,所提算法模型的累计概率分别提高了 7.83 个百分点和 10.75 个百分点,训练时间缩短了 8.56 s。原因在于所提算法模型不仅可以处理非稳态目标,还在大规模数据与参数优化过程中表现出良好的性能,故非常适合优化 CAE-SOM 深度学习算法。

4.5 经典定位算法的误差对比分析

本节按照上述所有实验的分析结果来确定算法的结构与参数,从而使 OCAE-SOM 算法达到最优的状态,进而选取文献[8]中离线阶段平滑去噪与在

线阶段支持向量机结合的方法(smoothing+SVM)、文献[10]中预处理相位与改进的加权 K 邻近(Weighted K -nearest Neighbor, WKNN)结合的算法(CSI-improved WKNN)、文献[11]中 CSI-XGBoost(CSI-Extreme Gradient Boosting)定位方法三种具有代表性的定位方式与所提算法模型在 LOS 布局中与 NLOS 布局中进行对比分析,使用累计概率分布与平均定位响应时间来验证所提算法的定位性能。4 种室内定位算法的定位精度比较结果如图 6 所示,不同算法的平均定位响应时间如表 5 所示。

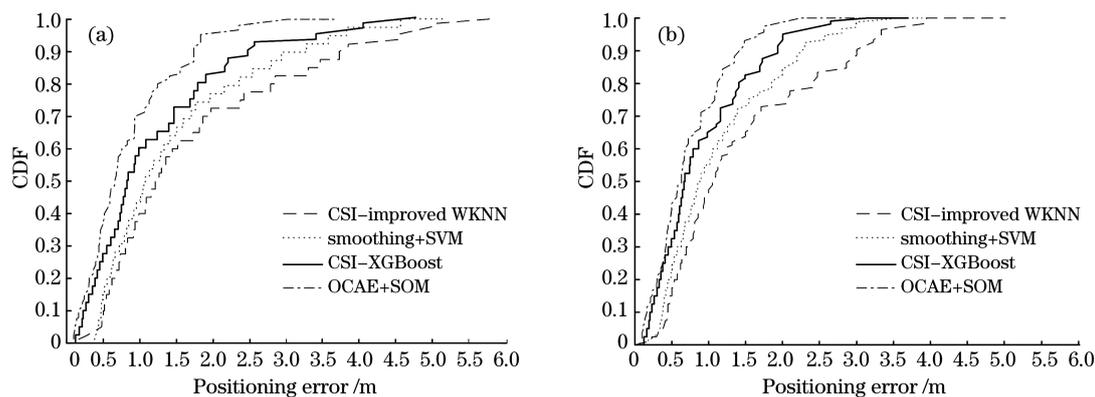


图 6 4 种室内定位算法在不同环境下的定位精度比较。(a)NLOS 布局;(b)LOS 布局

Fig. 6 Comparison of positioning accuracy of four indoor positioning algorithms in different environments.

(a) NLOS layout; (b) LOS layout

表 5 不同算法的平均定位响应时间

Table 5 Average location response time of different algorithms

Algorithm	CSI-improved WKNN	smoothing+SVM	CSI-XGBoost	OCAE-SOM
Average location response time / ms	10.249	8.935	8.027	6.914

从图 6 可以看到,在 LOS 布局与 NLOS 布局中,CSI-improved WKNN 算法整体上的效果比其余三种方式差;4 种定位方式虽最终累计的概率分布都可达 99%,但 OCAE-SOM 算法却能够在相对最小的定位误差内且累计概率分布最快达到 0.9869;在 NLOS 布局中,当室内定位误差在 2 m 以内时,OCAE-SOM、CSI-XGBoost、smoothing+SVM、CSI-improved WKNN 4 种算法在复杂环境中的定位累计概率分布分别达到了 0.9611、0.8334、0.7655 和 0.7249;在 LOS 布局中,4 种算法在定位误差 2 m 以内累计的概率分布分别达到了 0.9877、0.9471、0.8473 和 0.7412。从表 5 可以看到,所提定位算法在平均定位响应时间上也显著优于其他三种室内指纹定位算法,故所提算法在室内指纹定位的两种环境中的效果都最佳,远优于其他三种算法。

5 结 论

针对室内定位技术中定位精度较低和定位时间长等问题,提出了基于 OCAE-SOM 的室内定位算法。该算法通过全连接层将两种改进算法结合为整体的室内定位模型。实验结果表明,OCAE-SOM 算法不仅缩短了定位时间,提高了定位精度,而且不会破坏数据特征间联系的空间性。两种算法的结合与优化可以提升整个室内指纹定位模型的性能,简化以往的特征提取和分类过程分为两步进行训练的步骤,定位误差在 2 m 以内最快达到了 0.9869 的累计概率分布,整体性能均优于 CSI-XGBoost、CSI-SVM 和 CSI-WKNN 算法,但所提算法未能考虑人员处于动态对 CSI 数据的影响,这将是下一步研究并解决的问题。

参 考 文 献

- [1] Chen B, Yang X L. A WLAN access point localization algorithm based on probability density[J]. *Journal of Electronics & Information Technology*, 2015, 37(4): 855-862.
陈兵, 杨小玲. 一种基于概率密度的 WLAN 接入点定位的算法[J]. *电子与信息学报*, 2015, 37(4): 855-862.
- [2] Li H L, Qian Z H, Tian H L. Research on indoor localization algorithm based on kernel principal component analysis[J]. *Journal on Communications*, 2017, 38(1): 158-167.
李华亮, 钱志鸿, 田洪亮. 基于核函数特征提取的室内定位算法研究[J]. *通信学报*, 2017, 38(1): 158-167.
- [3] Dang X C, Ma P C, Hao Z J. Improved KNN indoor positioning method based on CSI[J]. *Transducer and Microsystem Technologies*, 2019, 38(10): 51-53.
党小超, 马平川, 郝占军. 基于 CSI 的改进 KNN 室内定位方法[J]. *传感器与微系统*, 2019, 38(10): 51-53.
- [4] Yang Z, Zhou Z M, Liu Y H. From RSSI to CSI: indoor localization via channel response[J]. *ACM Computing Surveys*, 2013, 46(2): 25.
- [5] Wang X S, Liu Y, Shi Z Q, et al. A privacy-preserving fuzzy localization scheme with CSI fingerprint[C]//2015 IEEE Global Communications Conference (GLOBECOM), December 6-10, 2015, San Diego, CA, USA. New York: IEEE Press, 2015: 15821049.
- [6] Chen R Z, Ye F. An overview of indoor positioning technology based on Wi-Fi channel state information[J]. *Geomatics and Information Science of Wuhan University*, 2018, 43(12): 2064-2070.
陈锐志, 叶锋. 基于 Wi-Fi 信道状态信息的室内定位技术现状综述[J]. *武汉大学学报·信息科学版*, 2018, 43(12): 2064-2070.
- [7] Dang X C, Li C X, Hao Z J. A two-phase indoor localization method combining RSS and CSI[J]. *Chinese Journal of Sensors and Actuators*, 2018, 31(8): 1258-1265.
党小超, 李彩霞, 郝占军. 一种 RSS 和 CSI 融合的二阶段室内定位方法[J]. *传感技术学报*, 2018, 31(8): 1258-1265.
- [8] Zhou M K, Huang W, Chen B, et al. Localization algorithm based on wireless channel state phase information optimization[J]. *Chinese Journal of Sensors and Actuators*, 2018, 31(6): 957-962.
周明快, 黄巍, 陈滨, 等. 基于无线信道状态相位信息优化的定位算法[J]. *传感技术学报*, 2018, 31(6): 957-962.
- [9] Wang Y, Xiu C, Zhang X, et al. WiFi indoor localization with CSI fingerprinting-based random forest[J]. *Sensors*, 2018, 18(9): 2869.
- [10] Liu Z Y, Chen L W, Huang L. Research on indoor fingerprint positioning technology based on CSI phase correction[J]. *Radio Engineering*, 2020, 50(2): 102-107.
刘兆岩, 陈立伟, 黄璐. 基于 CSI 相位矫正的室内指纹定位技术研究[J]. *无线电工程*, 2020, 50(2): 102-107.
- [11] Zhang X L, Xiu C D, Wang Y Z, et al. High-precision WiFi indoor localization algorithm based on CSI-XGBoost[J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2018, 44(12): 2536-2544.
张玄黎, 修春娣, 王延昭, 等. 基于 CSI-XGBoost 的高精度 WiFi 室内定位算法[J]. *北京航空航天大学学报*, 2018, 44(12): 2536-2544.
- [12] Chen H, Zhang Y F, Li W, et al. ConFi: convolutional neural networks based indoor Wi-Fi localization using channel state information[J]. *IEEE Access*, 2017, 5: 18066-18074.
- [13] Dang X C, Si X, Hao Z J, et al. A novel passive indoor localization method by fusion CSI amplitude and phase information[J]. *Sensors*, 2019, 19(4): 875.
- [14] Halperin D, Hu W J, Sheth A, et al. Predictable 802.11 packet delivery from wireless channel measurements[C]//Proceedings of the ACM SIGCOMM 2010 conference on SIGCOMM-SIGCOMM'10, August 30-September 3, 2010, New Delhi, India. New York: ACM Press, 2010: 159-170.
- [15] Dang X C, Huang Y N, Hao Z J, et al. Passive indoor human daily behavior detection method based on channel state information[J]. *Journal on Communications*, 2019, 40(4): 160-170.
党小超, 黄亚宁, 郝占军, 等. 基于信道状态信息的无源室内人员日常行为检测方法[J]. *通信学报*, 2019, 40(4): 160-170.
- [16] Seyfioglu M S, Özbayoglu A M, Gürbüz S Z. Deep convolutional autoencoder for radar-based classification of similar aided and unaided human activities[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2018, 54(4): 1709-1723.
- [17] Liu X. Feature detection from mobile libar using deep learning[D]. Oxford: Miami University, 2019.
- [18] Cui C. Convolutional polynomial neural network for improved face recognition[D]. Dayton: University of Dayton, 2017.

- [19] Chen Z M, Yeo C K, Lee B S, et al. Autoencoder-based network anomaly detection[C]//2018 Wireless Telecommunications Symposium (WTS), April 17-20, 2018, Phoenix, AZ, USA. New York: IEEE Press, 2018: 17803224.
- [20] Song L, Liu J. Second-order mutant reduction based on SOM neural network[J]. Journal of Software, 2019, 30(5): 1464-1480.
宋利, 刘靖. 基于 SOM 神经网络的二阶变异体约简方法[J]. 软件学报, 2019, 30(5): 1464-1480.
- [21] Qu N, Chen J T, Zuo J K, et al. PSO-SOM neural network algorithm for series arc fault detection[J]. Advances in Mathematical Physics, 2020, 2020: 6721909.
- [22] Kingma D P, Ba J. Adam: a method for stochastic optimization[EB/OL]. (2017-06-30)[2020-08-03]. <https://arxiv.org/abs/1412.6980>.
- [23] Tong W G, Li M X, Zhang Y K. Research on optimization algorithm of deep learning[J]. Computer Science, 2018, 45(S2): 155-159.
全卫国, 李敏霞, 张一可. 深度学习优化算法研究[J]. 计算机科学, 2018, 45(S2): 155-159.
- [24] Li X C, Wang L Y, Wang H T. CSI-cluster indoor fingerprint localization algorithm based on 3DCNN[J]. Journal of Chongqing University of Posts and Telecommunications (Natural Science Edition), 2020, 32(3): 345-355.
李新春, 王黎谚, 王浩童. 基于 3DCNN 的 CSI-cluster 室内指纹定位算法[J]. 重庆邮电大学学报(自然科学版), 2020, 32(3): 345-355.