

基于时间序列融合的室内定位方法

余莲杰, 李建峰, 徐睿, 张小飞

(南京航空航天大学电子信息工程学院, 南京 211106)

摘要: 提出了一种基于拉依达准则-相关系数-卷积神经网络 (Pauta criterion-correlation coefficient-convolutional neural networks, P-C-CNN) 的时间序列融合定位算法。P-C-CNN 方法整合了不同节点以及不同时间序列的数据点, 利用时间和空间数据的相互关联性, 提高了室内定位的精度和可靠性。首先, 该方法使用拉依达准则-相关系数 (Pauta criterion-correlation coefficient, P-C) 算法对到达角度 (Angle of arrival, AOA)-接收信号强度 (Received signal strength, RSS) 数据的异常值进行剔除, 提高了训练数据的质量。其次, 算法对数据进行随机间隔选取, 从而缩短模型训练时间, 同时较好地模拟在线定位阶段数据选取的不确定性, 减少模型对训练数据的过度拟合。再次, 传统单帧信息训练方法由于噪声混杂无法稳定提取信息特征, 所提算法在连续采集的时间序列数据中, 融合随机选取固定长度的多帧 AOA-RSS 数据, 然后利用卷积神经网络 (Convolutional neural networks, CNN) 进行特征提取, 避免了单帧信号定位中误差波动较大的问题。最后, 通过大量实际测试, 验证了所提方法的有效性。实验结果表明, 在典型室内环境中, 与仅采用 RSS 数据或者 AOA 信息的指纹定位算法相比, 本文算法的分类准确率由 91.6% 提高到了 96.4%, 定位精度从 1.3 m 提高到了 0.3 m; 与传统基于模型的 AOA-RSS 联合定位相比, 本文算法能较好解决实测中多径效应等干扰因素的影响, 定位精度从 1.1 m 提高到了 0.3 m。

关键词: 室内定位; 深度学习; 卷积神经网络; 联合定位; 时间序列

中图分类号: TN911.7 **文献标志码:** A

Indoor Positioning Based on Time Sequences Fusion

YU Lianjie, LI Jianfeng, XU Rui, ZHANG Xiaofei

(College of Electronic Information Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China)

Abstract: This paper proposes a novel indoor positioning algorithm based on time sequences fusion in Pauta criterion-correlation coefficient convolutional neural networks (P-C-CNN). The P-C-CNN approach integrates data points from different nodes and various time sequences, leveraging the interconnectedness of temporal and spatial data to enhance the accuracy and reliability of indoor positioning. Firstly, this method utilizes the Pauta criterion-correlation coefficient (P-C) algorithm to remove outliers in angle of arrival (AOA)-received signal strength (RSS) data, improving the quality of the training data. Secondly, the algorithm randomly selects data at intervals, reducing the training time of the model and effectively simulating the uncertainty of data selection in the online positioning phase, thus reducing overfitting of the

基金项目: 国家重点研发计划 (2020YFB1807602, 2020YFB1807604); 中国高校产学研创新基金 (2021ZYA0301); 江苏省博士后科研资助计划 (2020Z013); 中国博士后科研基金 (2020M681585)。

收稿日期: 2023-04-10; **修订日期:** 2023-08-29

model to the training data. Furthermore, the traditional single-frame information training method is unable to stably extract information features due to the mixture of noise. The proposed algorithm randomly selects multiple frames of fixed length from the continuously collected AOA-RSS data within time sequences fusion, and then employs convolutional neural networks (CNN) for feature extraction. This approach can avoid the issue of large error fluctuations commonly encountered in single-frame signal positioning. Finally, through extensive practical testing, this paper has validated the effectiveness of the proposed method. The experimental results demonstrate that in typical indoor environments, compared to fingerprint positioning algorithms that solely rely on RSS data or AOA information, the proposed algorithm achieves an improved classification accuracy from 91.6% to 96.4%, and the positioning accuracy is improved from 1.3 m to 0.3 m. Moreover, compared to the traditional model-based AOA-RSS joint positioning, this algorithm effectively addresses the influence of interference factors such as multipath effects observed in real-world measurements. The positioning accuracy is improved from 1.1 m to 0.3 m.

Key words: indoor positioning; deep learning; convolutional neural networks; joint positioning; time sequences

引 言

全球卫星导航系统(Global navigation satellite system, GNSS)为用户在室外提供精确的位置服务,但由于卫星信号无法穿透障碍物,无法用来进行室内定位。随着移动互联网与移动终端的蓬勃发展,人们在室内活动中花费越来越多的时间,有统计表明人们大部分的活动都是在室内完成的,这增强了对室内位置服务的需求,从而推动了室内定位技术的研究与发展。

目前,室内定位技术主要分为基于到达时间、基于信号特征以及基于信号方向3种^[1]。其中,基于到达时间的方法主要为到达时间(Time of arrival, TOA)^[2-3]和到达时间差(Time difference of arrival, TDOA)^[4-6],这两种方法定位精度高,但是接收设备之间需要严格的时间同步,且TOA/TDOA定位方法需要在不同的接收器之间测量信号到达的时间/时间差,因此需要接收器之间的距离足够大,以确保时间差的测量精度。在室内环境中,障碍物的存在会使信号传播路径更加复杂,信号到达时间/时间差的测量变得更加困难,这会导致TOA/TDOA方法在室内定位应用中精度较低。基于信号特征方法主要测量接收信号强度(Received signal strength, RSS)并构建指纹库,将待定位信号与指纹库中的信号进行匹配实现定位,RSS指纹库^[4,7-8]方法实现简单,而现有的设备如WiFi设备和蓝牙设备等均能方便采集信号的RSS信息,但是信号强度信息容易受到多种干扰的影响,如阴影效应、多径干扰和设备自身干扰等,导致最终的误差较大。基于信号方向方法主要为测量信号的到达角度(Angle of arrival, AOA)信息^[9],AOA信息获取简单,可以使用现有的无线通信系统的天线阵列实现,无需额外的硬件设施,也不需要设备之间严格的时间同步,但室内环境空间较小,由于信号传播过程中发生的反射和散射等因素导致多径效应,定位精度降低。

除了传统的单一信息定位算法外,联合定位成为了近年来的主要研究方向之一。Catovic等^[10]利用TOA/TDOA信息与RSS信息进行联合定位,在短距离特别是在参考设备附近,混合方案相对于传统的TOA和TDOA方案提供了更高的精度。Tomic等^[11]将AOA以及RSS信息结合,基于最小二乘法导出与AOA及RSS有关的目标函数进行定位,定位误差减少了3 m。Ding等^[12]提出了一种基于误差方差和测量噪声加权最小二乘(Error variance and measurement noise weighted least squares, ENWLS)的RSS/AOA混合室内定位方法,该方法使用一阶泰勒近似来近似线性加权最小二乘误差,并使用加权最小二乘估计来粗略估计目标的位置。

由于室内环境的复杂性和多样性,传统的基于物理模型的定位方法往往难以适应不同的场景和条件,因此基于机器学习的定位方法已经发展为室内定位的主要研究方向之一。通过训练并学习大量数据,可以自适应地调整模型,基于数据分析和特征学习,得到定位模型,从而准确地识别和预测室内位置信息,较好地提高室内定位的准确性和鲁棒性。Li等^[13]提出了一种指纹匹配和辅助节点协作的Wi-Fi室内定位方法,较好解决了室内多径问题。Wang等^[14]提出了基于Wi-Fi信号的信道状态信息(Channel state information, CSI)和深度置信网的Wi-Fi定位系统,利用卷积神经网络和长短时记忆网络(Long short-term memory, LSTM)从高维的CSI信息中学习指纹特征实现定位。Zhang等^[15]提出了一种基于Adaboost(通过迭代弱分类器而产生最终的强分类器的算法)的CSI指纹室内被动定位方法,基于Adaboost定位系统,利用CSI中的相位信息和集成学习(Ensemble learning, EL)方法来训练指纹图进行定位。Wang等^[16]提出了一种基于深度卷积网络的用于5 GHz Wi-Fi的室内定位指纹识别系统,从理论和实验上验证了使用AOA进行室内定位的可行性。

本文提出了一种基于P-C-CNN网络的多帧AOA-RSS时间序列融合定位方法。不同于传统算法使用单帧AOA/RSS信息,本文算法使用多帧AOA-RSS信息。对AOA-RSS信息组成的连续时间序列随机并连续选取固定帧数,组成二维数据矩阵,利用卷积神经网络的强大拟合能力以及特征提取能力将二维数据与位置信息进行建模得到定位模型。通过仿真以及实测证明,相比于现有的室内定位算法,本文算法较好解决实测中多径效应等干扰因素的影响,定位精度高,鲁棒性强。值得明确的是,尽管此方法在单目标检测中有其独特的优势,但它目前尚未适应复杂的多目标检测环境。在现有的室内定位技术中,大部分是针对单一目标进行设计。当涉及到多目标定位时,通常在时间或频率等因素上对目标进行区分,随后采用单一目标定位技术分别进行精确定位。

1 室内定位模型

室内定位方法的原理是建立室内位置与某种接收信号特征之间的联系,并拟合形成一个室内定位模型。特征可以是一种或多种,如目前的室内定位多采用基于RSS的指纹定位,而本文采用AOA和RSS联合特征信息进行定位。室内定位场景如图1所示,在一个边长为 B 的正方体区域内,使用蒙特卡罗方法在区域随机抽样,共抽取 M_a 个目标位置。假设共有 N 个接收节点和一个目标节点,接收节点位置分别为 $a_1, a_2, \dots, a_N (a_i \in \mathbf{R}^q, q=3, i=1, 2, \dots, N)$,未知目标节点位置为 $x (x \in \mathbf{R}^q, q=3)$ 。在如图1所示定位示意图中, $x = [x_1, x_2, x_3]^T, a_i = [a_{i1}, a_{i2}, a_{i3}]^T$ 。根据路径损耗模型可得第 i 个接收节点的接收信号强度 P_i 为

$$P_i = P_{d_0} - 10\gamma \lg\left(\frac{\|x - a_i\|}{d_0}\right) + n_i \quad i = 1, 2, \dots, n \quad (1)$$

式中: d_0 为参考距离; $\|x - a_i\|$ 为目标到接收节点的距离; γ 为环境因子,表示路径损耗指数; n_i 是一个均值为0、方差为 $\sigma_{n_i}^2$ 的高斯白噪声, $n_i \sim \mathcal{N}(0, \sigma_{n_i}^2)$ 。目标位置到第 i 个接收节点的俯角 θ_i 和方位角 φ_i 可分别表示为

$$\theta_i = \arctan\left(\frac{x_2 - a_{i2}}{x_1 - a_{i1}}\right) + m_i \quad (2)$$

$$\varphi_i = \arccos\left(\frac{x_3 - a_{i3}}{\|x - a_i\|}\right) + v_i \quad (3)$$




图1 室内定位模型

Fig.1 Indoor positioning model

式中: $\theta_i \in (-\pi, \pi)$, $\varphi_i \in (0, \pi)$, m_i 和 v_i 均为随机高斯白噪声,且 $m_i \sim \mathcal{N}(0, \sigma_{m_i}^2)$ 、 $v_i \sim \mathcal{N}(0, \sigma_{v_i}^2)$ 。

在第 m_a ($m_a \in [1, M_a]$)个位置采集AOA数据和RSS数据,第 e 次测得数据为 $\mathbf{x}_e = [\mathbf{X}_{\text{AOA}_e}, \mathbf{X}_{\text{RSS}_e}]$,其中, $\mathbf{X}_{\text{AOA}_e} = [\theta_{e_1}, \varphi_{e_1}, \theta_{e_2}, \varphi_{e_2}, \dots, \theta_{e_N}, \varphi_{e_N}]$, $\mathbf{X}_{\text{RSS}_e} = [X_{\text{RSS}_{e_1}}, X_{\text{RSS}_{e_2}}, \dots, X_{\text{RSS}_{e_N}}]$, $e \in (1, E)$, E 为该位置处的采样总次数。

室内定位一般分为两阶段,即离线训练阶段和在线定位阶段。离线训练阶段主要在各个位置采集信号信息,如AOA和RSS信息,结合室内定位算法,训练得到室内定位模型;在线定位阶段利用离线阶段得到的室内定位模型估计接收信号位置。

2 本文算法

由于室内环境复杂,多径效应、非视距传播等对接收信号影响较大,现有的室内定位算法无法很好地将信号源信息与位置信息拟合,而神经网络能够很好地从数据中进行特性提取,将AOA和RSS信息与室内位置信息进行拟合。近年来深度学习领域出现了非常多种类的神经网络方法,特别是Transformer网络,其衍生模型Swin Transformer^[17]更是在各个深度学习领域取得了前所未有的效果。但是,Transformer网络计算量大、结构复杂,无法满足室内定位领域实时性要求高、内存占用低以方便集成到移动端的要求。因此,本文采用较为简单的CNN网络架构,在其基础上加以适当的改进,提出了一种基于P-C-CNN的时间序列融合定位算法,该算法主要包括使用P-C算法对数据进行预处理、对多组AOA-RSS数据融合以及使用CNN网络对融合后的AOA-RSS数据进行分类定位3部分。

2.1 P-C算法对数据预处理

异常值数据通常不符合数据分布,会导致模型过度学习训练数据中的细节,从而难以泛化到测试数据。因此,采集的数据需要经过处理后才能用来训练,需要去除错误数据以及偏差过大的数据,可采用拉依达准则(Pauta criterion)准则和相关系数(Correlation coefficient)法去除异常数据。

拉依达准则,即 3σ 准则,是一种常用于数据分析和异常值检测的方法,它基于数据的标准差和均值来判断一个观测值是否异常。对于一组数据可以计算出其均值和标准差,如果某个数据点的值超过了均值加减3倍标准差的范围,那么就认为这个数据点是异常值,需要进行进一步的检查或剔除。对于某条数据 x_i ,计算其到达角数据以及RSS数据是否分别在该网格的到达角数据以及RSS数据的3倍标准差范围。对于不在3倍标准差范围的数据,可以进行剔除。图2为某次测量的接收数据,平均值计算为115.39,方差为1.66,根据 3σ 准则,有效数据的范围为[110.41, 120.37],即为图2红色框内的数据,其他数据可删除。且从图2也可以看出,AOA的值相对稳定,波动较小,适合用于室内定位算法。

上述的 3σ 准则对于单个节点的数据具有较好的效果,但无法处理多节点数据的异常值,因此可以根据不同数据之间的相关性排除异常数据。对于某一个网格点采集的数据 \mathbf{x}_e 来说,可计算其与其他所有采集数据的相关系数,相关系数的计算方式如下

$$\rho(\mathbf{x}_e, \mathbf{x}_{e_1}) = \frac{\text{Cov}(\mathbf{x}_e, \mathbf{x}_{e_1})}{\sigma_{\mathbf{x}_e} \cdot \sigma_{\mathbf{x}_{e_1}}} \quad (4)$$

式中: $\text{Cov}(\mathbf{x}_e, \mathbf{x}_{e_1})$ 表示数据 \mathbf{x}_e 和数据 \mathbf{x}_{e_1} 之间的协方差, $\sigma_{\mathbf{x}_e}$ 表示数据 \mathbf{x}_e 的标准差。如果数据 \mathbf{x}_e 与该网格点的其他大部分数据相关度都不高,那么该数据可以被看作异常数据,需要剔除。实际处理的时候,将某个网格内采集的所有数据与其他数据均计算一次相关系数,得到相关系数矩阵




图2 网格1节点1采集得到的方向角分布图
Fig.2 Distribution of directional angles collected from grid 1 base station 1

$$\rho = \begin{bmatrix} \rho_{1,1} & \rho_{1,2} & \cdots & \rho_{1,e} & \cdots & \rho_{1,E} \\ \rho_{2,1} & \rho_{2,2} & \cdots & \rho_{2,e} & \cdots & \rho_{2,E} \\ \vdots & \vdots & & \vdots & & \vdots \\ \rho_{e,1} & \rho_{e,2} & \cdots & \rho_{e,e} & \cdots & \rho_{e,E} \\ \vdots & \vdots & & \vdots & & \vdots \\ \rho_{E,1} & \rho_{E,2} & \cdots & \rho_{E,e} & \cdots & \rho_{E,E} \end{bmatrix} \quad (5)$$

式中： ρ_{e,e_1} 为第 e 个数据和第 e_1 个数据之间的相关系数。对其每行进行平均，得到 $\bar{\rho} = [\bar{\rho}_1, \bar{\rho}_2, \dots, \bar{\rho}_e, \dots, \bar{\rho}_E]$ ，如果 $\bar{\rho}_e < 0$ ，那么可以认为该数据与该网格点其他数据不相关，即可排除。

2.2 深度学习模型

2.2.1 卷积神经网络

卷积神经网络^[6,18-19]是一种前馈神经网络，通常应用于图像处理和语音识别领域。相较于全连接神经网络，它引入了卷积层和池化层，可以更好地处理高维输入数据，避免参数爆炸和过拟合等问题。

卷积神经网络中的卷积层是核心部分，通过卷积操作提取输入数据的特征，输出一个二维的特征图。首先，将数据送入卷积层，卷积操作可以看做是一个滑动窗口，将每个位置窗口内的数据与卷积核进行逐元素相乘，再将结果相加得到输出的特征图中的一个元素。二维卷积操作的数学表达式为

$$h_{i,j} = \sum_{m=0}^{A-1} \sum_{n=0}^{B-1} w_{m,n} x_{i+m,j+n} + b \quad (6)$$

式中： $h_{i,j}$ 为输出特征图中的一个元素， $w_{m,n}$ 为卷积核的权重， $x_{i+m,j+n}$ 为输入数据中对应的元素， b 为偏置项， A 和 B 代表卷积核的大小， i 和 j 为计算结果的行列索引。然后，将卷积层的计算结果通过激活层进行非线性变换，得到 $X_{act,i,j} = \sigma(h_{i,j})$ ，其中 σ 是激活函数， $X_{act,i,j}$ 为激活层的计算结果。最后，将 $X_{act,i,j}$ 通过池化层减少卷积层输出的空间大小，得到计算结果 $X_{poll,i,j} = \text{pool}(X_{act,i,j})$ ，即为卷积层的输出特征图。

卷积神经网络使用卷积层和池化层来提取数据的特征，而全连接神经网络将所有神经元都连接在一起，可以有效地进行分类。在实际应用中，两种神经网络通常会被结合在一起，用于处理复杂的多维数据。例如，一个数据分类网络可以先使用卷积神经网络提取数据的特征，然后使用全连接神经网络进行分类或者预测。

2.2.2 本文所用卷积神经网络

本文所用卷积神经网络如图3所示，输入首先通过两个不同的通道，第1个通道包括2个CNN层（卷积核的大小均为 2×2 ）、2个Dropout层以及1个拉直层（Flatten），第2个通道为1个拉直层和1个全连接层（Fully connected layers, FC），两层的输出相加后通过3个全连接层进行分类，得到输入数据所属的类别。第2个通道将来自前1个层的输出直接连接到后1个层的输入，从而减少了该通道的参数数量。参数数量越少，越不容易过拟合。

本文神经网络与常规的卷积神经网络相比，输入数据通过两个不同的通道分别进行特征提取，卷积层用于提取方向角、俯仰角以RSS之间的联系，全连接层用于将低维特征映射到高维特征空间，最后相加得到综合特征。且由于数据维度较小，本文方法没有使用卷积神经网络中常见的池化层。




图3 卷积神经网络结构图

Fig.3 Convolutional neural network structure diagram

2.3 基于P-C-CNN的AOA-RSS时间序列融合定位

2.3.1 随机时间序列融合

对于常见的通信信号来说,均具有周期性,如Wi-Fi信号的频率为2.4 GHz代表1 s内经历了 2.4×10^9 次周期变化。经过实测,选择其中某次测量得到的100个连续数据,得到如图4所示的结果,可以看出AOA和RSS信息具有一定的周期性,表明不同数据在时间维度上有一定的依赖关系,利用卷积神经网络可提取相邻时间序列之间以及相邻节点数据之间的联系。

随机时间序列数据融合过程如图5所示,其中 A_z 为信号到各接收感知节点的方向角, E_L 为信号到各接收感知节点的俯仰角,RSS为信号到各接收感知节点的信号强度,横向为一次采集数据。首先,选取 χ 组一维数据,将其重新组合成二维数据,如选取4组12特征的一维数据,组合成大小维 6×8 的二维数据,二维数据的两个维度值应接近方便后续卷积。然后,跳过后面 R_i 组一维数据,这里的 i 为第几次选取数据, R_i 为随机数,范围为 $[0, \text{int}(\chi/2)]$ 。重复上述两个步骤,直至最后一组数据。此处的 R_i 为模拟在线定位时采集数据的随机性,也可防止训练好的定位模型出现过拟合。

如果节点数为4,选取4组数据进行融合,每组数据有12个特征值(图6中黑色虚线框内数据即为一组),即原始数据为 $X \in \mathbf{R}^{4 \times 12}$,融合后的数据为 $\tilde{X}, \tilde{X} \in \mathbf{R}^{6 \times 8}$,其卷积过程如图6所示,其中红色代表方位角数据,绿色代表俯角数据,蓝色代表RSS数据,选取卷积核的大小为 2×2 。利用CNN算法不仅能提取不同节点之间的联系,还能提取不同时间序列之间的联系。如(1,1)的值为第1组数据的 $\varphi_{11}, \theta_{11}, X_{\text{RSS}_{11}}$ 以及 $X_{\text{RSS}_{12}}$ 与卷积核相乘得到,里面包含了不同节点数据之间的联系。(2,4)的值为第1组数据的 $\varphi_{24}, \theta_{21}, X_{\text{RSS}_{14}}$ 以及 $X_{\text{RSS}_{21}}$ 与卷积核相乘得到,里面包含了不同时间序列数据之间的联系。

2.3.2 算法流程及总结

随机时间序列融合卷积神经网络定位算法主要内容为将采集的AOA和RSS数据使用P-C算法去除异常值后随机并连续地选取,组合成二维数据,送入本文改进后的CNN网络提取特征,接着利用全连接神经网络进行分类,得到信号所属的网格,从而实现定位。算法的具体步骤如下所示。

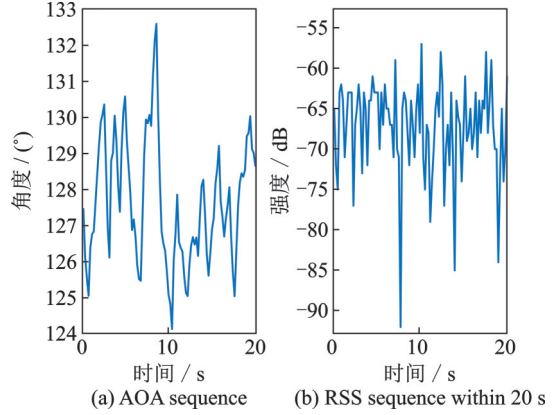


图4 周期变化的AOA序列和RSS序列实测图
Fig.4 Actual measurement of AOA and RSS sequences with periodic changes

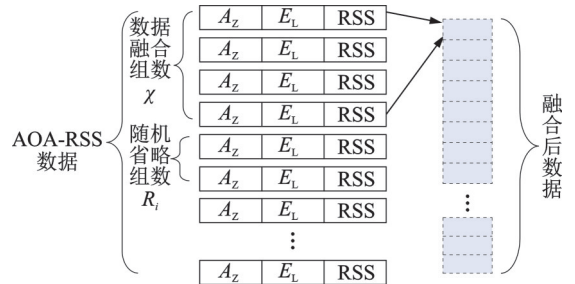


图5 随机时间序列融合示意图
Fig.5 Schematic diagram of random time sequences fusion




图6 融合后的数据卷积示意图
Fig.6 Schematic of convolution of the fused data

离线训练阶段:

(1) 数据采集: 对待定位区域选择若干个待定位目标位置, 在每个目标位置采集多次 RSS 数据和 AOA 数据, 第 i 次采集的数据即为 $x_i = (X_{AOA}, X_{RSS})$ 。

(2) 数据剔除: 采集的数据波动较大, 导致部分位置处数据采集效果差, 对其使用 P-C 算法进行数据剔除。

(3) 随机时间序列数据融合: 将同一位置处的多帧一维数据 x_i 组合成二维数据, 记为 X^κ , X^κ 为输入数据矩阵 χ 的第 κ 个数据, 对应的输出数据为 y^κ 。

(4) 神经网络训练: 首先, 使用卷积神经网络提取数据特征, 将数据 X^κ 送入卷积神经网络, 得到信号的特征。最后, 使用全连接神经网络进行预测, 输出为网格所在的位置 \hat{y}^κ 。

(5) 输出训练后的定位模型。

在线定位阶段:

(1) 采集并处理数据: 此处同在线阶段的步骤(1~3)。

(2) 使用定位模型预测目标位置: 将前一步输出的数据利用离线训练阶段得到的模型进行预测, 得到目标位置。

本文提出的 P-C-CNN 算法相比于现有算法, 有如下优点:

(1) 传统算法如基于最小二乘法的 AOA-RSS 联合定位算法^[19]需要知道信号发射的功率才可以计算得到信源的位置, 本文算法可直接根据接收信号功率(强度)预测信号的位置。

(2) 部分算法如 DeepFi^[14]算法、iPos-5G^[20]等, 需要通过复杂的设备和软件获取信号的 CSI 信息, 本文仅需通过非合作被动阵列天线即可获取所需的 AOA-RSS 信息。

(3) 本文算法将一维 AOA-RSS 数据转化为二维数据, 利用卷积神经网络可以提取不同时间帧数据之间的联系以及不同信号特征之间的联系, 提高算法的鲁棒性。

(4) 信号的 AOA 与 RSS 信息具有一定周期性, 本文采用随机时间序列能较好地模拟在线阶段数据选取的随机性, 减少训练数据选取的随机性对预测的影响。

(5) 本文所用的 P-C 算法能有效地识别并处理 AOA-RSS 数据的异常值, 提高训练数据的质量, 进而提高算法的预测准确率。

3 实验与结果分析

3.1 仿真分析

本节对所提方法进行了仿真分析, 并与传统 AOA-RSS 联合定位算法对比。为了与实测环境尽量接近, 接收节点数 N 设为 4, 仿真区域大小 B 设为 30 m, 蒙特卡罗随机采样数设为 50 000, 接收信号强度、俯角以及方位角中的噪声的方差 σ 均设为相同值, 范围为 $[1, 6]$ 。分别采用最小二乘法(Least squares, LS)^[19]、距离差平方最小二乘法(Squared range least squares, SR-LS)^[11]、二阶锥规划(Second order cone programming, SOCP)^[11]、ENWLS 方法以及本文所提方法(P-C-CNN)对上述所得仿真数据进行计算, 得到如图 7 所示结果。从图 7 可以看出, 本文算法与传统基于模型的算法相比, 定位精度高, 且在不同噪声下定位误差均较为稳定, 鲁棒性强。




图 7 不同算法均方根差($N=4, \gamma=2, B=30$ m, $L=40$ dB, $M=50$ 000)

Fig.7 RMSE of different algorithms ($N=4, \gamma=2, B=30$ m, $L=40$ dB, $M=50$ 000)

3.2 实测分析

3.2.1 实测数据采集

为了验证上述算法的实际效果,选择在学校会议室进行验证工作。如图8所示,在会议室天花板的4个角落各安装一个信号接收设备,将待定位区域进行网格划分,本次实验划分网格的大小为 $0.5\text{ m} \times 0.5\text{ m}$,总共划分25个网格。将信号源标签依次置于不同网格中,每个网格内采集2 min以上数据,设备1 s采集5次数据,也就是每个网格内总共采集600次以上数据。根据AOA算法即可计算得到4个节点的信号到达角信息,第 e 次采集可得 $X_{\text{AOA}e} = (\theta_{e_1}, \varphi_{e_1}, \theta_{e_2}, \varphi_{e_2}, \dots, \theta_{e_4}, \varphi_{e_4})$,RSS信息由设备可以直接测量得出, $X_{\text{RSS}_{e_i}} = (X_{\text{RSS}_{e_1}}, X_{\text{RSS}_{e_2}}, \dots, X_{\text{RSS}_{e_4}})$,从而,每次测量可以得到数据为 $x_e = (\theta_{e_1}, \varphi_{e_1}, \dots, \theta_{e_4}, \varphi_{e_4}, X_{\text{RSS}_{e_1}}, \dots, X_{\text{RSS}_{e_4}})$,每帧数据有12个信号特征数据。



图8 室内定位场景实拍图

Fig.8 Indoor positioning scene photographs

3.2.2 神经网络参数设置

通过2.3节的数据融合方法将AOA-RSS数据融合,得到 \tilde{X} ,作为输入数据,数据对应位置id为 y 。实验采用的卷积神经网络见图3,其中有两个卷积层,两个卷积层卷积核的大小均为 2×2 ;有4个全连接层,最后一层为 1×25 ,对应25个网格。对于12个时间序列融合的CNN网络各层对应的参数如表1所示,总共分为10层,总的训练参数有118 609个。

表1 神经网络结构

Table 1 Convolutional neural network structure

层数	操作	输出矩阵大小	激活函数	参数数量
1	Flatten	(1,144)	无	0
2	Conv2D	(1,16,11,11)	ReLU	80
3	Dropout	(1,16,11,11)	无	0
4	Conv2D	(1,8,10,10)	ReLU	520
5	Dropout	(1,8,10,10)	无	0
6	Flatten	(1,800)	无	0
7	Dense	(1,800)	ReLU	116 000
8	Dense	(1,128)	ReLU	102 528
9	Dense	(1,64)	ReLU	8 256
10	Dense	(1,25)	tanh	1 625

3.2.3 定位误差统计

本文采用基于网格分类的定位方法,最终得到的预测位置为网格中心位置,因此统计定位误差时需要统计网格内部的平均误差,可用网格内各个点到网格中心的平均距离表示。本文中网格的大小为 $0.5\text{ m} \times 0.5\text{ m}$,因此可以得到网格内各个点到网格中心的平均距离为

$$d_{\text{gridError}} = \frac{1}{A} \int_0^{0.5} \int_0^{0.5} \sqrt{(x-0.25)^2 + (y-0.25)^2} dx dy \quad (7)$$

式中: A 为网格面积,即为0.25,得到 $d_{\text{gridError}} = 0.19\text{ m}$ 。若最后定位平均误差为 d_{Mean} ,那么总体定位误差为

$$d_{\text{All}} = d_{\text{Mean}} + d_{\text{gridError}} \quad (8)$$

3.2.4 实测结果

为了验证本文方法的效果,分别将相邻的4、8以及12帧信号特征数据进行组合,结果如表2所示。

表2 不同算法准确率和定位精度

Table 2 Accuracy and positioning accuracy of different algorithms

算法	不同组合组数准确率/%				不同组合组数定位精度/m			
	1	4	8	12	1	4	8	12
P-C-CNN	92.50	94.66	96.20	96.40	0.28	0.26	0.26	0.25
CNN(AOA-RSS数据)	90.88	92.46	94.02	94.80	0.85	0.67	0.62	0.65
WKNN(RSS数据)	54.53	79.11	83.04	83.69	1.10	0.70	1.09	1.28
WKNN(AOA-RSS数据)	91.91	92.27	92.28	92.48	1.06	1.02	1.00	1.07
AOA(AOA数据)	无	无	无	无	1.37	1.13	1.03	1.01
AOA-RSS-LS(AOA-RSS数据)	无	无	无	无	0.93	0.76	0.73	0.71

各算法的准确率如图9所示。图9给出了4种算法在不同时间序列数据组合下的效果,帧数为1表示不融合数据,P-C-CNN为本文算法,CNN为不采用随机间隔的算法,加权K近邻(Weighted K nearest neighbors, WKNN)表示加权最小二乘法,分为仅使用RSS数据的WKNN算法和同时使用AOA-RSS数据的WKNN算法。从图9可以看出:(1)采用了AOA-RSS数据融合算法的准确率明显高于基于一维数据的算法,且准确率随着数据组合数量上升,从92.5%提升至96.4%,这说明了本文所用数据融合算法对算法准确率的提升有较大帮助;(2)本文提出的P-C-CNN算法明显优于其他定位算法,这说明本文所用P-C算法对异常数据具有较好的剔除效果,且本文所提出的CNN网络明显优于传统CNN网络。

各算法的定位误差如图10所示,其中AOA-RSS-LS表示为基于最小二乘法的AOA-RSS联合定位算法,对于此算法的不同帧数据融合为将多组数据平均。可以看出:(1)本文提出的算法在融合4帧数据时定位误差为0.26 m,8帧时为0.26 m,12帧时为0.25 m;直接基于AOA室内定位算法的定位误差为1.01 m,基于RSS的指纹定位误差为1.28 m;相比其他算法,本文提出的算法在定位精度上有着较大提

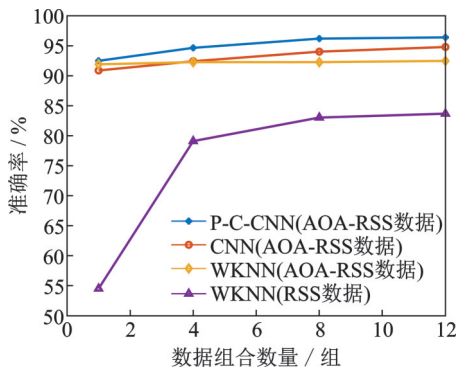


图9 组合不同组数的信号数据后不同机器学习算法的准确性

Fig.9 Accuracy of different machine learning algorithms after combining signal data of different groups

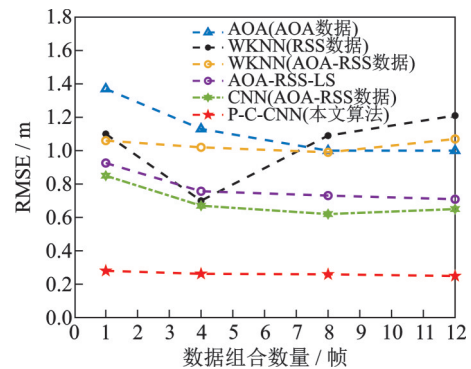


图10 不同算法均方根差随信号组合组数变化曲线

Fig.10 Variation of RMSE with the number of signal combination groups for different algorithms

升。(2)本文算法在网格分类准确率高的同时定位精度也较高,说明错误定位到周围区域的概率较大,算法较好地拟合了AOA-RSS信息与位置之间的关系。

为了验证本文算法的稳定性,分别进行了4次实验,每次的定位环境均有部分差异,如部分障碍物摆放位置发生了变动。实验的预测准确率和定位误差如图11所示,准确率和定位误差波动较小,这充分证明了本文算法稳定性较好。

4 结束语

在实际室内定位环境中,由于多径效应等干扰,RSS值波动严重,无法简单地用模型描述RSS值与位置之间的关系,不适合单独作为信号位置的特征值。

AOA值相比RSS值,受环境因素影响小,波动较小,但也受到多径效应等因素干扰。本文提出了一种基于P-C-CNN网络的多帧AOA-RSS随机时间序列融合室内定位算法,在提取相邻时间信号特征之间的联系后有效地解决了多径干扰以及特征值波动较大的问题。实测表明,本文算法应用于室内定位,能有效减小多径效应的影响,提高室内定位的精度。

参考文献:

- [1] KIM GEOK T, ZAR AUNG K, SANDAR AUNG M, et al. Review of indoor positioning: Radio wave technology[J]. *Applied Sciences*, 2021, 11(1): 279.
- [2] FEIGL T, EBERLEIN E, KRAM S, et al. Robust TOA-estimation using convolutional neural networks on randomized channel models[C]//*Proceedings of 2021 International Conference on Indoor Positioning and Indoor Navigation*. Lloret de Mar, Spain: IEEE, 2021: 1-8.
- [3] XIONG H, PENG M, GONG S, et al. A novel hybrid RSS and TOA positioning algorithm for multi-objective cooperative wireless sensor networks[J]. *IEEE Sensors Journal*, 2018, 18(22): 9343-9351.
- [4] GHANNOUCHI F M, WANG D, TIWARI S. Accurate wireless indoor position estimation by using hybrid TDOA/RSS algorithm[C]//*Proceedings of 2012 IEEE International Conference on Vehicular Electronics and Safety*. Istanbul, Turkey: IEEE, 2012: 437-441.
- [5] ZHAO Z, ZHANG H, GAN L. A multi-station signal sorting method based on TDOA grid clustering[C]//*Proceedings of 2021 IEEE 6th International Conference on Signal and Image Processing*. Nanjing, China: IEEE, 2021: 773-778.
- [6] NIITSOO A, EDELHÄÜBER T, MUTSCHLER C. Convolutional neural networks for position estimation in TDOA-based locating systems[C]//*Proceedings of 2018 International Conference on Indoor Positioning and Indoor Navigation*. Nantes, France: IEEE, 2018: 1-8.
- [7] ZHOU R, YANG Y, CHEN P. An RSS transform-based WKNN for indoor positioning[J]. *Sensors*, 2021, 21(17): 5685.
- [8] LEE S, CHO B, KOO B, et al. Kalman filter-based indoor position tracking with self-calibration for RSS variation mitigation [J]. *International Journal of Distributed Sensor Networks*, 2015, 11(8): 674635.
- [9] XU J, MA M, LAW C L. AOA cooperative position localization[C]//*Proceedings of IEEE GLOBECOM 2008 IEEE Global Telecommunications Conference*. New Orleans, LA, USA: IEEE, 2008: 1-5.
- [10] CATOVIC A, SAHINOGLU Z. The Cramer-Rao bounds of hybrid TOA/RSS and TDOA/RSS location estimation schemes [J]. *IEEE Communications Letters*, 2004, 8(10): 626-628.
- [11] TOMIC S, MARIKJ M, BEKO M, et al. Hybrid RSS-AoA technique for 3-D node localization in wireless sensor networks [C]//*Proceedings of 2015 International Wireless Communications and Mobile Computing Conference*. Dubrovnik, Croatia:




图11 不同次测试时实验准确率和均方根差

Fig.11 Experimental accuracy and RMSE in different tests

IEEE, 2015: 1277-1282.

- [12] DING W, CHANG S, LI J. A novel weighted localization method in wireless sensor networks based on hybrid RSS/AOA measurements[J]. *IEEE Access*, 2021, 9: 150677-150685.
- [13] LI Q, LI W, SUN W, et al. Fingerprint and assistant nodes based Wi-Fi localization in complex indoor environment[J]. *IEEE Access*, 2016, 4: 2993-3004.
- [14] WANG X, GAO L, MAO S, et al. DeepFi: Deep learning for indoor fingerprinting using channel state information[C]// *Proceedings of 2015 IEEE Wireless Communications and Networking Conference*. New Orleans, LA, USA: IEEE, 2015: 1666-1671.
- [15] ZHANG Y, LID, WANG Y. An indoor passive positioning method using CSI fingerprint based on adaboost[J]. *IEEE Sensors Journal*, 2019, 19(14): 5792-5800.
- [16] WANG X, WANG X, MAO S. Deep convolutional neural networks for indoor localization with CSI images[J]. *IEEE Transactions on Network Science and Engineering*, 2020, 7(1): 316-327.
- [17] LIU Z, LIN Y, CAO Y, et al. Swin transformer: Hierarchical vision transformer using shifted windows[C]// *Proceedings of 2021 IEEE/CVF International Conference on Computer Vision*. Montreal, QC, Canada: IEEE, 2021: 9992-10002.
- [18] ZHANG A, LIPTON Z C, LI M, et al. Dive into deep learning[M]. University Printing House Shaftesbury Road, United Kingdom: Cambridge University Press, 2023.
- [19] YU K. 3-D localization error analysis in wireless networks[J]. *IEEE Transactions on Wireless Communications*, 2007, 6(10): 3472-3481.
- [20] RUAN Y, CHEN L, ZHOU X, et al. iPos-5G: Indoor positioning via commercial 5G NR CSI[J]. *IEEE Internet of Things Journal*, 2023, 10(10): 8718-8733.


作者简介:



余莲杰(1998-),男,硕士研究生,研究方向:机器学习、室内定位、信号识别,E-mail: ryanyu@nuaa.edu.cn。



李建峰(1988-),通信作者,男,副教授,博士,研究方向:阵列信号处理、辐射源定位、雷达信号处理,E-mail:lijianfeng@nuaa.edu.cn。



徐睿(2000-),男,博士研究生,研究方向:智能测向、辐射源定位,E-mail: rey.xu@nuaa.edu.cn。



张小飞(1977-),男,教授,博士生导师,研究方向:移动通信、阵列信号处理、通信信号处理,E-mail: zhangxiaofei@nuaa.edu.cn。

(编辑:陈珺)