

基于改进深度置信网络的 UWB 无线定位方法

李元绪[†]

(中国石油大学(华东) 计算机科学与技术学院, 山东 青岛 266580)

摘要: 针对传统指纹定位算法中接收信号强度值在室内复杂环境中波动较大, 指纹信息不可靠, 造成定位精度不足的问题, 提出了一种以测距值作为指纹信息的基于深度置信网络和极限学习机的超宽带定位方法。首先在深度置信网络底层采用多个堆叠受限玻尔兹曼机对输入数据做无监督学习, 来提取深层次特征, 然后在顶层选用极限学习机对输入数据及位置标签进行有监督学习。建立指纹库阶段, 为优化指纹采集过程并减少人工勘测成本, 提出一种基于高斯过程回归的超宽带指纹库扩充方法。真实场景下实验结果显示, 视距环境和非视距环境中, 该定位方法均能够达到厘米级定位精度。

关键词: 超宽带定位; 深度置信网络; 极限学习机; 高斯过程回归

中图分类号: TP391

文献标识码: A

UWB Wireless Positioning Method Based on Improved Deep Belief Network

LI Yuanxu[†]

(College of Computer Science and Technology, China University of Petroleum (Huadong),
Qingdao, Shandong 266580, China)

Abstract: The received signal strength in the traditional fingerprint positioning algorithm fluctuates greatly in the complex indoors environment, which generates unreliable fingerprint information and results in insufficient positioning accuracy. We propose an ultra-wideband (UWB) fingerprint positioning method based on deep belief network (DBN) combined with extreme learning machine (ELM) using the range value as fingerprint information. Firstly, the multiple stacked restricted Boltzmann machines are used at the bottom of DBN to do unsupervised learning on the input data to extract deep features, and the ELM is used at the top layer to do supervised learning on the input data and location labels. In the offline fingerprint database stage, a UWB fingerprint database expansion method based on Gaussian process regression is proposed to optimize the fingerprint acquisition process and reduce the cost of manual surveying. The experimental results show that the algorithm can achieve centimeter-level positioning accuracy in both line of sight (LOS) and non line of sight (NLOS) environments.

Key words: ultra-wideband positioning; deep belief network; extreme learning machine; Gaussian process regression

随着物联网和无线通信技术的快速发展, 人们对基于位置服务(Location Based Services, LBS)的需求不断提升, 尤其是在定位方面。在室外, 全球导航卫星系统(Global Navigation Satellite Sys-

tem, GNSS) 提供较高精度的定位, 可以满足大多数定位需求, 然而, GNSS 信号太弱, 无法穿透墙壁, 并且在室内衰减严重, 难以取得较好的定位效果。现有的基于射频识别(Radio Frequency Iden-

收稿日期: 2023-04-07

基金项目: 国家自然科学基金资助项目(61902431)

作者简介: 李元绪(1998-), 男, 山东济宁人, 硕士, 研究方向: 人工智能, 室内定位。

[†] 通信联系人, E-mail: 2205817578@qq.com

tification, RFID)、蓝牙(blueetooth, BT)、无线保真(Wireless Fidelity, Wi-Fi)等定位技术,定位精度都在米级,往往无法满足人们对于高精度定位服务的需求。

相比于上述室内无线定位技术,超宽带(Ultra Wide Band, UWB)定位技术凭借其高时间分辨率、强抗多径能力、低功耗等特点^[1],能够在复杂的室内环境中取得优异表现。在 UWB 室内定位无线技术中,常见定位方法主要有基于代数求解的几何定位方法^[2]和基于指纹匹配的指纹定位方法^[3]。基于代数求解的几何定位方法需要获取基站的准确位置坐标作为先验知识,然而在复杂多变的室内环境中,UWB 信号在传输过程中会受到多径效应或由于障碍物遮挡产生非视距(Non Line of Sight, NLOS)误差,导致几何定位方法定位精度下降^[4]。文献[5]提出了一种简单到达时间差(Time Difference of Arrival, TDOA)算法,将 TDOA 定位方程转化为非标准的最小二乘形式,然后通过迭代的思想计算出标签的收敛坐标,但在非视距环境下定位精度不足。文献[6]提出了一种基于模糊综合评价的 NLOS 识别和抑制误差的方法,采用等式约束泰勒级数鲁棒最小二乘位置估计来抑制 NLOS 误差,一旦复杂环境下的 NLOS 范围估算值存在较大偏差,该方法会有较大的定位误差。文献[7]通过研究 UWB 天线的时钟偏移、节点之间的相对速度引起的测距误差,提出了一种 UWB 距离测量的状态检测和误差补偿方法。

基于指纹匹配的指纹定位方法并不需要获取基站的位置坐标,可以避免由于布置基站不准确带来的定位误差,指纹定位方法能够通过获取更丰富的指纹信息来充分模拟当前所处的实际定位环境^[8],其定位精度比几何定位方法更高,在 NLOS 环境下仍然可以取得较高定位精度,因此,指纹定位方法是室内定位中应用最为广泛的技术之一。文献[9]提出了一种使用信号强度(Received Signal Strength, RSS)作为指纹信息的算法,通过采集 RSS 值,然后使用 RSS 的数学模型估计基站和标签之间的距离,最终经过欧几里德距离公式计算得出标签位置坐标。文献[10]提出了一种在二维空间中拥有两个基站使用基于混合 RSS/TDOA 方法的固定目标被动定位方法,根据 UWB 无线电信号的振幅和传播延迟时间的测量结果来优化标签到基站的距离。但在室内复杂多变的环境中 RSS 值波动较大,会产生指纹信息不可靠的问题,从而造成定位精度不足。

针对以上问题,根据 UWB 信号时间分辨率高、测距值精确的优点使用测距值作为指纹信息来构建指纹数据库,与传统的指纹数据库相比,具有更高的可靠性。在离线建立指纹数据库阶段,为优化指纹采集过程并减少人工勘测成本,提出了一种基于高斯过程回归(Gaussian Process Regression, GPR)的 UWB 指纹库扩充方法。在定位过程中,提出一种基于深度置信网络(Deep Belief Network, DBN)和极限学习机(Extreme Learning Machine, ELM)的 UWB 无线定位方法。

本文在第 1 节介绍了基于高斯过程回归的 UWB 指纹库扩充方法,在第 2 节阐述了深度置信网络的构建、基于 DBN-ELM 的 UWB 指纹定位方法,在第 3 节对上述模型进行了实验分析,验证了本文所提出方法的性能优势,最后在第 4 节对全文研究内容进行了总结。

1 基于 GPR 的 UWB 指纹库扩充方法

指纹数据库的建立如图 1 所示,在参考点处,定位标签可以获得到不同基站之间的距离,将这组测距值以向量的形式保存起来。一般来说,在定位区域内采集的参考点数量越多,后续在线匹配阶段的指纹数据库将会更加丰富^[11],最终得到的定位精度也会更高。为了创建拥有丰富信息的指纹数据库,这要求在定位区域中的不同参考点处采集定位标签对应的指纹,如果参考点设置较密集或定位区域较大,则需要耗费较多人力和时间成本。因此,快速有效地构建指纹库对室内定位技术推广有着重要意义。

在本节中,根据室内场景中已采集参考点位置和对应的指纹数据,利用 GPR 模型对指纹库进行扩充。首先构建已采集到的参考点位置与指纹之间的关系模型,然后对未采集参考点的指纹信息进行预测,从而在不增加额外工作量的条件下扩充指纹库,提高室内定位精度。

将位置坐标及其对应的测距指纹信息设为训练集,GPR 目的是研究输入与输出之间的关系^[12]。GPR 模型如式(1)所示。

$$f: T \rightarrow y \quad (1)$$

上式中, T 为参考点位置, $T = (T_1, T_2, \dots, T_n)$, y 为参考点到各基站之间的测距指纹信息, $y = (y'_1, y'_2, \dots, y'_n)$,则位置与指纹信息的高斯分布表示如式(2)所示。

$$\begin{bmatrix} y'_1(T_1) \\ \vdots \\ y'_N(T_n) \end{bmatrix} \sim N \left(\begin{bmatrix} m(T_1) \\ \vdots \\ m(T_n) \end{bmatrix}, K(T) \right) \quad (2)$$

上式中, $m(\cdot)$ 表示均值, $K(\cdot)$ 表示方差, 且有

$$K(T) = \begin{bmatrix} k(T_1, T_1) & \cdots & k(T_1, T_n) \\ k(T_2, T_1) & \cdots & k(T_2, T_n) \\ \vdots & & \vdots \\ k(T_n, T_1) & \cdots & k(T_n, T_n) \end{bmatrix} \quad (3)$$

上式中, $k(T_i, T_j)$ 如式(4)所示。

$$E[(y'(T_i) - m(T_i))(y'(T_j) - m(T_j))] \quad (4)$$

若 $\alpha_i \sim N(0, \sigma_N^2)$ 表示独立同分布的测量噪声, 则参考点的位置信息 T 和其对应的测距信息可以表示为式(5)所示。

$$y_i(T) = y'_i(T) + \alpha_i \quad (5)$$

当采集参考点数量较少时, 可以通过已采集数据预测未标定区域的指纹信息来扩充指纹库。当扩充参考点数量为 m 时, 则新的位置信息 $T^r = (T_1^r, T_2^r, \dots, T_m^r)$, 能够通过 GPR 模型预测出新的测距指纹信息 y^r 。

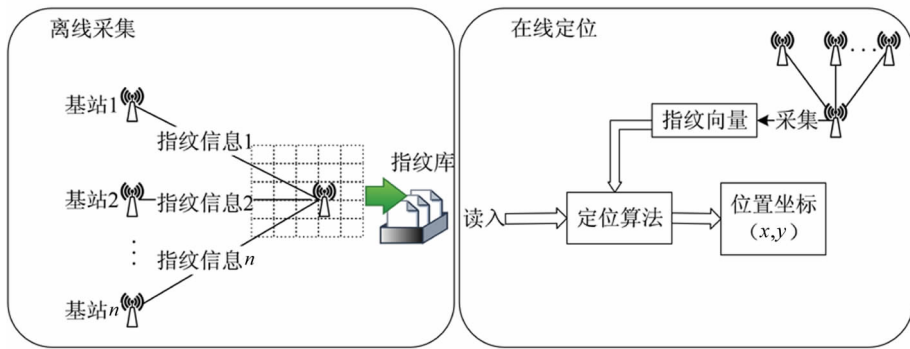


图1 建立指纹库

2 基于 DBN-ELM 的 UWB 无线定位方法

2.1 深度置信网络的构建

DBN 是 Hinton 教授提出的一种由多层非线性变量连接组成的概率生成模型, 它建立了数据和标签之间的联合概率分布, 具有较强的学习能力, 能够在原始数据中提取有效特征, 以便于进行准确分类及预测^[13]。它是由多层堆叠的受限玻尔兹曼机(Restricted Boltzmann Machine, RBM)和一层反向传播(Back Propagation, BP)网络组成, 其结构如图2所示。

DBN 网络的训练阶段主要包括两个过程, 分别是无监督学习和反向微调。

(1) 无监督学习

在 DBN 底层部分, 采用对比散度算法初步进行权值初始化, 该算法是一种快速无监督贪婪训练 RBM 的方法。首先从可见层到隐含层形成一个向量来传递输入数据, 然后通过吉布斯采样的方法使用隐含层的神经元来重构可见层的输入神经元, 并再次传递到隐含层。这个过程不断循环, 直到达到收敛条件或达到最大迭代次数。最终, 整个过程可

以用来训练 DBN 模型并生成有效的特征表示, 这些特征可以用于不同的机器学习任务, 如分类、聚类、回归等。

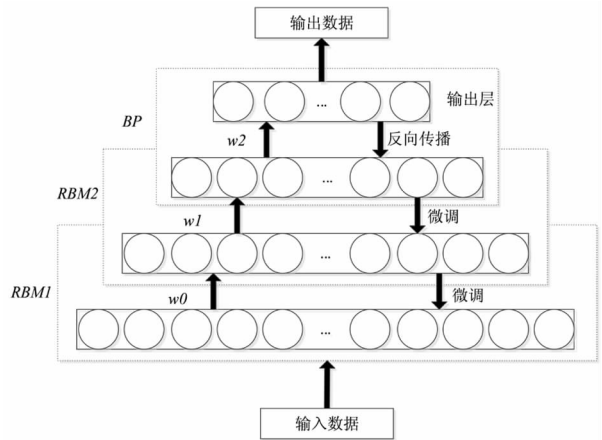


图2 DBN 结构图

(2) 反向微调

在 DBN 的无监督学习阶段完成后, 可以使用带标签数据进行有监督学习反向微调, 来优化模型的参数。在反向微调的过程中, 首先利用已知的标签信息计算出输出误差值, 来估算输出层和前一层之间的误差, 并通过逐层反向传播训练来求得各层

之间的误差值,然后 DBN 通过 BP 神经网络层来调整各层节点的参数,最终完成 DBN 整体节点权值的全局微调。通过这个过程,可以进一步提高 DBN 模型的性能和准确度,为机器学习任务的应用提供更加优秀的特征提取和分类能力。

DBN 训练阶段的两个过程结合了无监督学习与有监督学习各自的优势,提高了网络的建模能力,加快了模型收敛速度并且提高了分类和预测效果。

2.2 改进的深度置信网络

传统的 DBN 在底层经过多个 RBM 的无监督学习之后,顶层使用 BP 网络对整个网络参数进行全局微调,BP 算法对浅层网络的训练效率和模型准确度效果不错^[14],但是随着隐藏层数的增加,算法的训练效率会明显下降,易陷入局部最优。为了提高训练速度和网络模型的泛化能力,使用 ELM 代替 DBN 顶层的 BP 网络,来进行有监督的学习,从而完成对整个 DBN 节点权值的全局微调。ELM 是基于单隐藏层的前馈神经网络(Single Layer Feedforward Neural Network, SLFN)的快速训练算法,SLFN 的单个隐藏层将输入层连接到输出层,通过输入层与隐藏层之间随机生成的连接权重及阈值建立模型间联系^[15]。ELM 结构如图 3 所示。

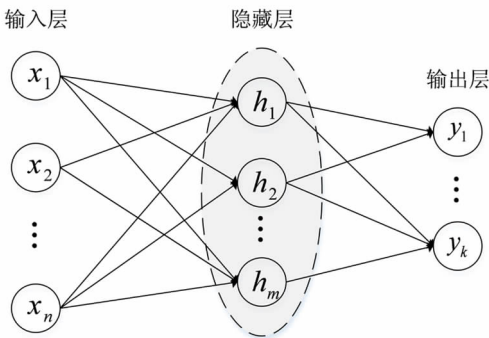


图 3 ELM 结构图

改进后的深度置信网络使用 ELM 替换掉 BP 网络,去掉了 BP 神经网络复杂的学习过程,同时极大提高了整个网络的学习速度,使模型具有良好的泛化性。DBN-ELM 模型既具有深度置信网络通过无监督学习来获取原始数据深层次特征的特点,也具有 ELM 学习速率高且强泛化能力的特点,结合了二者之间的优势,弥补了自身的不足。DBN-ELM 模型利用 DBN 对位置原始数据进行无监督学习,并将 ELM 用于有监督学习,加快模型训练效率,提高模型的识别能力,能够缩短离线指

纹库的训练时间并且提高在线指纹匹配的准确率。

假设 DBN-ELM 模型结构隐含层的层数为 n , 则把输入层到第 $n-1$ 个隐含层作为 DBN 部分用于无监督学习,那么把第 $n-1$ 个隐含层作为 ELM 的输入层,第 n 个隐含层作为 ELM 的隐含层,二者组成一个完整的 ELM 用于有监督学习,DBN-ELM 模型如图 4 所示。

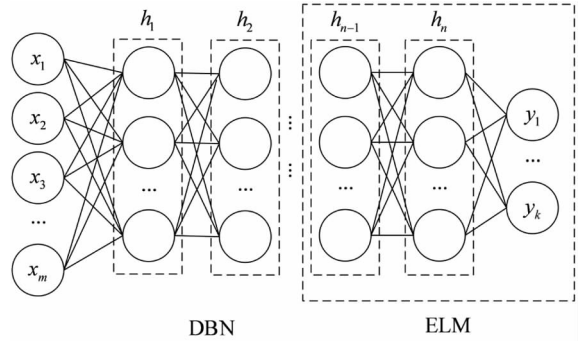


图 4 DBN-ELM 结构图

在 DBN-ELM 模型的网络结构确定之后,首先采用 DBN 的无监督学习的方式来训练输入层到第 $n-1$ 个隐含层,接下来采用 ELM 算法来计算第 $n-1$ 个隐含层与输出层之间权重和偏置,用于整体网络的全局微调,则该网络可表示为式(6):

$$\sum_{i=1}^N \beta_i g(\omega_i h_{n-1} + b_i) = o_j, j = 1, 2, \dots, M \quad (6)$$

上式中, N 表示第 n 个隐含层节点个数, M 表示第 $n-1$ 个隐含层节点个数, β_i 表示第 n 个隐含层和输出层之间的权值, $g(\cdot)$ 为激活函数, ω_i 表示第 $n-1$ 个隐含层和第 n 个隐含层之间的连接权值, h_{n-1} 表示第 $n-1$ 个隐含层, b_i 表示第 $n-1$ 个隐含层和第 n 个隐含层之间的偏置。

DBN-ELM 整个模型学习的目标是使得输出的误差最小,其误差函数可以表示为式(7)、式(8):

$$t_j = \sum_{i=1}^N \beta_i h_{(n,j)}, j = 1, 2, \dots, M \quad (7)$$

$$\sum_j \parallel o_j - t_j \parallel = 0 \quad (8)$$

$$h(\omega_1, \dots, \omega_N, b_1, \dots, b_N, h_{(n-1,1)}, \dots, h_{(n-1,M)}) = \begin{bmatrix} g(\omega_1 \cdot h_{(n-1,1)} + b_1) & \dots & g(\omega_N \cdot h_{(n-1,1)} + b_N) \\ \vdots & & \vdots \\ g(\omega_1 \cdot h_{(n-1,M)} + b_1) & \dots & g(\omega_N \cdot h_{(n-1,M)} + b_N) \end{bmatrix} \quad (9)$$

上述问题的求解可以简化为式(10):

$$h_n \beta = T \quad (10)$$

上式中, h_n 表示第 $n-1$ 个隐含层到第 n 个隐含层的输出。

β 和 T 可由式(11)表示:

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_N^T \end{bmatrix}, T = \begin{bmatrix} t_1^T \\ \vdots \\ t_M^T \end{bmatrix} \quad (11)$$

整个 DBN-ELM 模型学习的目标是使得输出的误差最小,那么上述问题的求解过程也就等同于求 w_i, b_i, β 使得:

$$\|h_n(w_i, b_i)\beta - T\| = \min_{w, b, \beta} \|h_n(w_i, b_i)\beta - T\| \quad (12)$$

结合 ELM 算法的特性,能够获得赋予初值的输出矩阵 h_n ,将 DBN-ELM 模型的整个过程最后转化为线性问题 $h_n\beta = T$ 的求解,则:

$$\beta = h_n^+T \quad (13)$$

上式中, h_n^+ 为 h_n 的 Moore-Penrose 广义逆矩阵。DBN-ELM 就是以找到最小输出权值 β 为目的,让输出结果逼近真实值。

基于 DBN-ELM 的 UWB 定位方法可以分为四个阶段:数据获取阶段,预处理阶段,训练阶段和定位阶段。在数据获取阶段,与传统指纹定位算法使用 RSS 值作为指纹量相比,该算法根据 UWB 信号时间分辨率高、测距值精确的优点采用测距值来作为指纹量用于构建指纹数据库,提高了训练模型的环境表达能力。预处理阶段对测距值进行了缺失、异常值处理,然后将处理后的数据归一化,得到标准化的输入数据集。训练阶段,利用 DBN-ELM 模型对输入数据集进行学习训练,提取可以

有效表达位置信息的深层次特征作为指纹,并将与之对应的位置坐标来构建指纹库。定位阶段,利用训练后的 DBN-ELM 模型以及指纹库就可以完成在线采集数据对目标位置的预测。

3 PSO 优化 DBN-ELM

DBN 由底层无监督学习的预训练和顶层有监督学习的反向微调两个阶段组成。先用原始测距数据来训练 RBM,得到 DBN 的前向传递模型和初始的权值参数。为了让网络具有良好的泛化性能,避免存在过拟合问题,还需要优化每个网络层的神经元个数。这里采用粒子群优化(Particle Swarm Optimization, PSO)算法^[16]来优化整个 DBN-ELM 模型,从而提升模型在 UWB 指纹定位中的训练速度和稳定性。

在使用 PSO 算法优化 DBN 的过程中,选择测试样本交叉验证的平均精度作为算法的适应度函数。在 PSO 算法的迭代过程中,不断更新 DBN 隐藏层的层数和对应的神经元个数,直至找到全局最优值或达到最大迭代次数,从而得到优化后的 DBN 模型。另外,由于随机初始化权重参数可能会导致 DBN 陷入局部最优状态,采用 ELM 来训练 DBN 的输出特征,然后计算输出误差来微调整个模型的参数。整个模型的优化过程如图 5 所示。

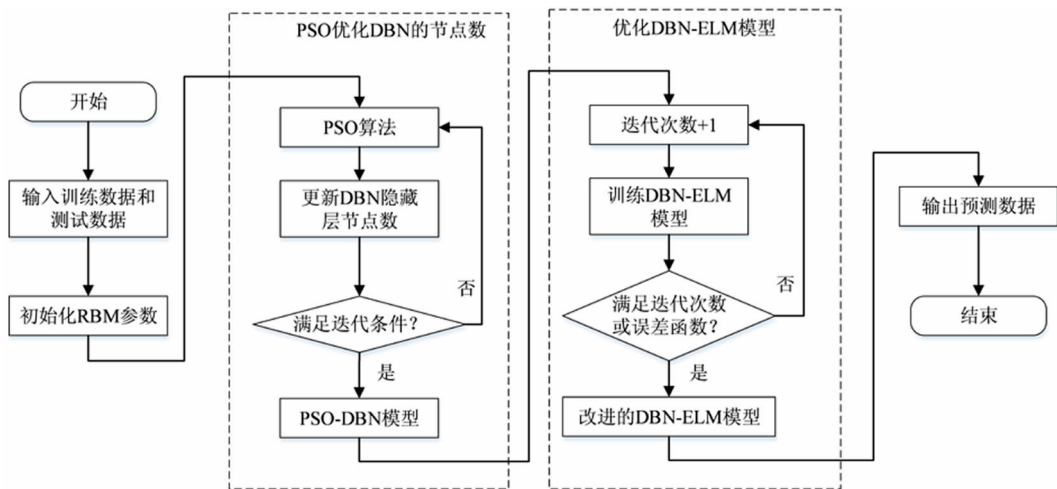


图 5 PSO 优化 DBN-ELM 模型流程图

PSO 算法优化 DBN-ELM 模型的具体实现步骤为:

- (1) 将采集测距数据划分为训练集和测试集。
- (2) 训练过程中,经过 PSO 对种群内粒子寻

优,得到最佳粒子位置所对应的最终 DBN 隐含层数及对应神经元个数。

- (3) 使用 ELM 训练 DBN 输出特征,对模型的参数进行微调。

(4)如果到达最大迭代次数或者符合误差最小界限,则停止训练。通过计算测试数据与预测数据的误差来检验模型的性能,最后输出预测数据。

3.1 实验环境搭建

为了研究算法在真实室内环境下的定位性能,选择在山东省青岛市中国石油大学(华东)研究生 3 号楼的 7 楼走廊来进行定位实验,在实验区域中布置 4 个 UWB 基站,分别放置在实验区域的 4 个顶角处。同时将实验区域划分为 45 个网格,每个网格面积为 $60 \times 60 \text{ cm}^2$,取其中 23 个网格的中心点作为参考点来采集指纹数据,如图 6 所示。




图 6 参考点分布图

实验使用 Decawave 公司开发的超宽带设备 DW1000 在每个参考点连续获取 200 条数据,数据预处理后存入指纹库。DW1000 采用充电宝供电,放置在三角架上。分别构建 LOS、NLOS 两种场景进行实验,并建立坐标系,用于评估最终定位效果。

(1)构建指纹数据库

将测距值作为指纹用于构建指纹数据库的实现流程是,在选定的实验区域中,选取 m 个参考点,对于每个参考点接收到的来自 n 个基站的测距值,将其连同参考点坐标一起存入指纹数据库,离线指纹库 F 如式(14)所示。

$$F = \begin{pmatrix} x_1 & y_1 & d_1^1 & d_1^2 & \cdots & d_1^n \\ x_2 & y_2 & d_2^1 & d_2^2 & \cdots & d_2^n \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ x_m & y_m & d_m^1 & d_m^2 & \cdots & d_m^n \end{pmatrix} \quad (14)$$

(2)优化指纹数据库

离线采样阶段中建立的指纹库数据应正确反映实验区域中的环境特征,但在实际定位场景中,错误指纹也会增大定位误差,降低定位精度。指纹数据库需要一个优化过程来,降低算法复杂度和定位误差,提高定位精度。

首先对每个参考点与不同基站间的多次测距值分别求平均值,接下来将从每个基站采集得到的测距值与对应的平均值做差,保留差值较小的前 90%数据作为优化后的指纹信息,最后存入指纹数据库用于训练 DBN-ELM 模型。

(3)扩充指纹数据库

根据已采集的 23 个网格的参考点位置坐标和测距值信息构成的训练指纹,用 GPR 模型描述数据之间的关系,通过建立的 UWB 指纹库扩充模型来预测未标定区域内 22 个网格点的测距指纹信息,共计 45 个参考点及其测距指纹信息来构建指纹库,降低前期指纹的部署和采集工作量。

3.2 实验结果分析

(1)扩充指纹数据库对定位精度的影响

用基于 GPR 的 UWB 指纹库扩充方法对未标定区域进行预测,最后将扩充后的 45 个参考点指纹用于后续定位。此外,对未扩充的原始指纹库对应的定位精度进行了比较。定位过程中,均采用基于 DBN-ELM 的 UWB 定位方法来对位置进行估计,选取 8 个测试点,每个测试点处采集 10 组数据,分析扩充指纹库前后定位误差。根据定位结果,采用预测位置与真实位置之间的欧式距离来表示定位误差,定位误差累计分布如图 7 所示。

根据 PSO 优化 DBN-ELM 模型结果,将 DBN-ELM 模型隐含层数设置为 4,从输入层到第 3 个隐含层的神经元分别设置为 4-8-16-13,ELM 的隐含层为第 4 个隐含层,设置第 4 个隐含层神经元个数为 27。

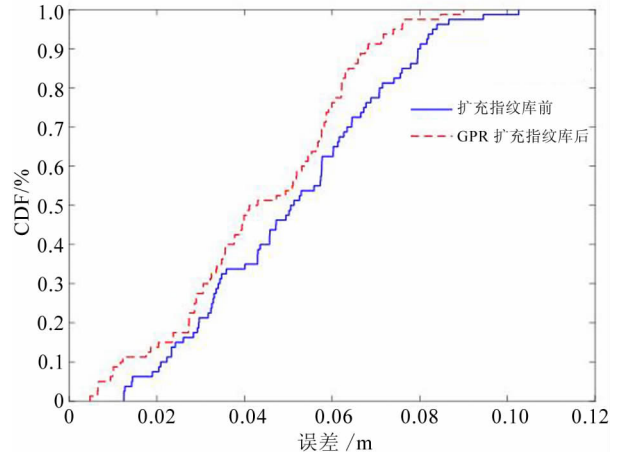


图 7 定位误差累积分布函数图

如图 7 所示,使用 GPR 扩充指纹库后定位精度比扩充指纹数据库前有所提高。实验结果说明 UWB 指纹扩充模型能够在相对较少数据样本的

条件下,使用 GPR 来建立参考点坐标和测距值之间的关系,用于预测未标定区域测距值来扩充指纹库,进一步提高了室内定位精度。UWB 指纹扩充模型无需增加勘测测量就能采集更多数据样本,减少了人力和时间成本,具有一定的实际应用价值。

(2) DBN-ELM 对定位精度的影响

分别在 LOS、NLOS 环境下进行定位实验,利用提出的基于 DBN-ELM 的 UWB 定位方法对 8 个测试点做位置预测,然后进行定位精度分析。分别计算 LOS、NLOS 环境下的定位误差。LOS 环境下测试点的真实位置与预测位置之间的误差如表 1 所示。

由表 1 可得,在 LOS 环境下采用 DBN-ELM 模型的 8 次实验定位误差均小于 0.1 m,最大误差为 0.0900 m,最小误差仅为 0.0101 m。由此可以得出结论,在 LOS 环境中将 DBN-ELM 模型用于室内待定位目标节点的位置预测能够获得较高的定位精度。

表 1 LOS 环境下测试点真实位置与预测位置

测试点	真实坐标	预测坐标	误差/m
1	(0.6,1.8)	(0.5966,1.8739)	0.0740
2	(0.6,2.4)	(0.6731,2.4524)	0.0900
3	(0.6,3.0)	(0.5250,3.9606)	0.0847
4	(0.6,3.6)	(0.6408,3.5863)	0.0430
5	(1.2,1.8)	(1.1697,1.8560)	0.0637
6	(1.2,2.4)	(1.2559,2.4067)	0.0563
7	(1.2,3.0)	(1.1903,2.9972)	0.0101
8	(1.2,3.6)	(1.2751,3.5877)	0.0761

NLOS 环境下测试点的真实位置与预测位置之间的误差如表 2 所示。

表 2 NLOS 环境下测试点真实位置与预测位置

测试点	真实坐标	预测坐标	误差/m
1	(0.6,1.8)	(0.4998,1.6120)	0.2131
2	(0.6,2.4)	(0.4548,2.3656)	0.1491
3	(0.6,3.0)	(0.4667,3.0194)	0.1347
4	(0.6,3.6)	(0.4312,3.5883)	0.1692
5	(1.2,1.8)	(1.2674,1.5924)	0.2182
6	(1.2,2.4)	(1.0838,2.2441)	0.1944
7	(1.2,3.0)	(1.0368,2.9222)	0.1807
8	(1.2,3.6)	(1.2816,3.6291)	0.0866

由表 2 可得,在 NLOS 环境下采用 DBN-ELM 模型的 8 次实验定位误差均小于 0.22 m,最大误差为 0.2182 m,最小误差为 0.0866 m。与 LOS 环境下相比,定位误差增大,定位精度有所降低,但仍然保持在 0.22 m 内,说明 DBN-ELM 模型对于室内目标的位置预测表现出良好定位性能,能满足实际应用需求。

以上结果可以看出,无论是在 LOS 环境还是 NLOS 环境中,DBN-ELM 模型都可以获得较高定位精度,且适用于 NLOS 环境,模型具有稳健性。

(3) 不同定位算法的定位精度比较分析

分别在 LOS、NLOS 环境下进行定位实验,利用本文提出的 DBN-ELM 模型与传统 DBN 和加权 K 近邻相结合 (Weighted K-Nearest Neighbor, WKNN)^[17] 等定位方法对 8 个测试点做位置预测,然后进行定位精度分析,结果如表 3 所示。

表 3 定位算法的性能对比

定位方法	定位环境	最大误差/m	最小误差/m	平均误差/m
WKNN	LOS	0.4375	0.2165	0.3504
WKNN	NLOS	0.5271	0.2997	0.4153
7DBN	LOS	0.2421	0.0916	0.1865
DBN	NLOS	0.3982	0.1366	0.2953
DBN-ELM	LOS	0.0900	0.0101	0.0622
DBN-ELM	NLOS	0.2182	0.0866	0.1628

在 LOS 和 NLOS 两种环境下分别对 8 个测试点利用提出的 DBN-ELM 模型以及传统 DBN 和 WKNN 方法做位置预测,在 LOS 环境下,WKNN 方法的平均误差为 0.3504 m,传统 DBN 方法的平均误差为 0.1865 m,提出的 DBN-ELM 模型的平均误差仅为 0.0622 m,与 WKNN 方法相比平均误差降低了 0.2882 m,与传统 DBN 方法比平均误差降低了 0.1243 m。在 NLOS 环境下,WKNN 方法的平均误差为 0.4153 m,传统 DBN 方法的平均误差为 0.2953 m,提出的 DBN-ELM 模型的平均误差为 0.1628 m,与 WKNN 方法相比平均误差降低了 0.2525 m,与传统 DBN 方法比平均误差降低了 0.1325 m。

可以看出,提出的 DBN-ELM 模型应用于 UWB 室内指纹定位方法可以获得较高的定位精度,相比于 WKNN 和传统 DBN 其对 NLOS 环境更加适用。

4 结 论

提出了一种基于DBN-ELM的UWB指纹定位方法。针对传统的指纹定位算法中大多采用RSS值用作指纹信息,但在室内复杂多变的环境中RSS值波动较大,会造成指纹信息不可靠,从而造成定位精度不足的问题,根据UWB信号时间分辨率高、测距值精确的优点采用测距值来作为指纹量用于构建指纹数据库,提高了训练模型的环境表达能力。另外在建立指纹库阶段,提出了一种基于GPR的UWB指纹库扩充方法,降低了人力和时间成本。基于DBN-ELM的UWB无线定位方法在LOS环境下平均定位精度能够达到0.0622 m,在NLOS环境下平均定位精度为0.1628 m,能够满足大部分人群对室内定位精度的需求。

参考文献

- [1] 卜伟雄,朱蕴璞,何子路. 基于交互式多模型的UWB定位算法及实验研究[J]. 国外电子测量技术, 2021, 40(4): 22-26.
- [2] TSCHIRSCHNITZ M V, WAGNER M, PAHL M O, et al. A generalized TDOA/TOA model for TOF positioning[C]. 2019 International Conference on Indoor Positioning and Indoor Navigation (IPIN), 2019: 1-8.
- [3] HAN X, HE Z. A wireless fingerprint location method based on target tracking[C]. 2018 12th International Symposium on Antennas, Propagation and EM Theory (ISAPE), 2018: 1-4.
- [4] 李勇,柳建. 基于IA-BP神经网络的UWB室内定位系统[J]. 电子测量技术, 2019, 42(5): 109-112.
- [5] 何成文,袁运斌,潭冰峰. 一种基于UWB TDOA定位模式的迭代最小二乘算法[J]. 大地测量与地球动力学, 2021, 41(8): 806-809.
- [6] YU K, WEN K, LI Y, et al. A novel NLOS mitigation algorithm for UWB localization in harsh indoor environments[J]. IEEE Transactions on Vehicular Technology, 2019, 68(1): 686-699.
- [7] 李荣冰,王念曾,刘建业,等. 面向相对导航的UWB测距误差估计与补偿方法[J]. 仪器仪表学报, 2019, 40(5): 28-35.
- [8] ALAKHRAS M, HUSSEIN M, OUSSALAH M. Location fixing and fingerprint matching fingerprint map construction for indoor localization[J]. Journal of Sensors, 2020: 7801752.
- [9] IBNATTA Y, KHALDOUN M, SADIK M. Indoor localization system based on mobile access point model MAPM using RSS with UWB-OFDM[J]. IEEE Access, 2022, 10: 46043-46056.
- [10] IVANOV S, KUPTSOV V, BADENKO V, et al. RSS/TDoA-based source localization in microwave UWB sensors networks using two anchor nodes[J]. SENSORS, 2022, 22(8).
- [11] 王轩,陈国良,曹晓祥. 自适应K值及指纹库扩充的WLAN室内定位方法[J]. 测绘科学, 2020, 45(7): 26-32.
- [12] LAI C, LONG P. Indoor localization method based on gaussian process regression and WiFi fingerprint[J]. Journal of Electronic Measurement and Instrument, 2021, 35(2): 186-193.
- [13] WANG G, QIAO J, GUAN L, et al. Review and prospect on deep belief network[J]. Acta Automatica Sinica, 2021, 47(1): 35-49.
- [14] 王震洲,李鑫圆. 基于BP神经网络的pH试纸自动检测系统[J]. 电子测量与仪器学报, 2019, 33(10): 109-112.
- [15] YILDIRIM H, OZKALE M R. An enhanced extreme learning machine based on liu regression[J]. NEURAL PROCESSING LETTERS, 2020, 52(1): 421-442.
- [16] CHEN N, ZHOU H. A comparison study of PSO with different update equations in solving economic dispatch problem[C]. 2020 39th Chinese Control Conference (CCC), 2020: 6028-6032.
- [17] WANG H C, WANG X X, XUE Y, et al. UWB-based indoor localization using a hybrid WKNN-LSTM algorithm[C]. Information Technology, Networking, Electronic and Automation Control Conference (ITNEC), 2020: 1720-1725.