

基于深度学习的 WiFi 指纹室内定位算法^{*}孙浩^{1,2} 谷玉海^{1,2} 吕兰^{1,2}

(1.北京信息科技大学现代测控教育部重点实验室 北京 100192; 2.北京信息科技大学机电工程学院 北京 100192)

摘要:为解决复杂室内环境中多路径效应和信号遮挡导致的 WiFi 定位精度下降问题,提出一种融合卷积神经网络(CNN)与双向长短期记忆网络(BiLSTM)的信号强度指示(RSSI)指纹定位算法。该方法结合 CNN 的空间特征提取能力与 BiLSTM 的时间序列建模优势,实现对 RSSI 信号的时空特征深度融合。通过 MATLAB 仿真,与 CNN、CNN-LSTM、线性回归(LR)、KNN、随机森林(RF)、梯度提升决策树(GBDT)和支持向量机(SVM)等方法进行对比。实验结果表明,算法在随机点定位测试中性能最优:平均误差降低 52.1%,最大误差降低 53.2%,标准差降低 55.6%。进一步的 Monte Carlo 随机轨迹验证表明,CNN-BiLSTM 在连续定位中具有更高精度与鲁棒性。研究结果证明该模型能有效抑制 RSSI 信号波动,为复杂室内环境下的高精度 WiFi 指纹定位提供可行方案。

关键词:室内定位;深度学习;WiFi 定位;CNN;BiLSTM

中图分类号:TN98;TP183 **文献标识码:**A **国家标准学科分类代码:**470.4017

Deep learning-based WiFi fingerprinting algorithm for indoor positioning

Sun Hao^{1,2} Gu Yuhai^{1,2} Lyu Lan^{1,2}

(1. Key Laboratory of Measurement and Control of Mechanical and Electrical System Technology, Beijing Information Science & Technology University, Beijing 100192, China; 2. College of Mechanical and Electrical Engineering, Beijing Information Science & Technology University, Beijing 100192, China)

Abstract: To address the degradation of WiFi fingerprinting accuracy caused by multipath effects and signal obstruction in complex indoor environments, this paper proposes an RSSI-based localization algorithm integrating a convolutional neural network (CNN) and a bidirectional long short-term memory network (BiLSTM). The method leverages the spatial feature extraction capability of CNN and the temporal sequence modeling strength of BiLSTM to achieve deep spatiotemporal feature fusion. MATLAB simulation experiments compare the proposed model with CNN, CNN-LSTM, LR, KNN, RF, GBDT and SVM. Results show that the proposed CNN-BiLSTM achieves the best performance, reducing average, maximum and standard deviation of positioning errors by 52.1%, 53.2% and 55.6%, respectively. Monte Carlo trajectory experiments further demonstrate the superior accuracy and robustness of CNN-BiLSTM in continuous localization. The proposed model effectively suppresses RSSI fluctuations and provides a feasible solution for high-precision indoor WiFi fingerprinting.

Keywords: indoor localization; deep learning; WiFi positioning; CNN; BiLSTM

0 引言

室内的位置服务(location based services, LBS)^[1]在工厂、酒店、商场等环境内扮演重要角色,其主要实现导航、物流和人员跟踪等功能。室内定位服务因卫星信号弱而无法实现稳定高效的定位,通常需要借助物联网(internet of things, IoT)技术,即 WiFi^[2]、蓝牙^[3]、射频识别^[4]和超宽带(ultra-wideband, UWB)^[5]定位提供位置信息。其中基于

WiFi 的指纹定位算法受到众多学者的关注,其存在成本低廉、部署广泛^[6]、能够利用现有的无线网络基础设施进行定位、精度较高等优点。

在实际定位工况中,复杂的室内环境往往存在多路径效应^[7]和信号遮挡等情况,影响了室内定位精度。随着近些年深度学习技术的快速发展,也为定位技术带来了新的思路。余晴等^[8]通过长短期记忆网络(long short-term memory, LSTM)网络进行场景分类,基于足绑式仪器实现

定位;彭铎等^[9]通过卷积神经网络-LSTM(convolutional neuralnetwork-LSTM,CNN-LSTM)进行声速预测以实现水下定位;吴仕勋等^[10]通过 LCVAE-CNN 方法实现基于 WiFi 的指纹定位方法,然而 LCVAE 网络存在训练复杂,需要调整参数等缺点;Li 等^[11]通过 CNN-双向长短期记忆网络(bidirectional long short-term memory,BiLSTM)+迁移学习实现基于 UWB 的指纹定位方法,但是 UWB 定位存在硬件成本高传输距离受限等问题;王开亮等^[12]针对传统 WiFi 指纹定位中单一距离度量鲁棒性不足的问题,提出了一种基于投票机制的定位算法,通过联合多种距离度量选取公共近邻点并进行概率加权,有效避免异常近邻点的干扰,显著提升了定位精度。在基于 WiFi 的室内定位场景中,常见问题包括:WiFi 信号易受干扰、信号强度指示(received signal strength indicator,RSSI)波动较大,以及现有方法往往忽略指纹数据的时空关系,因而难以实现精准可靠的定位。为解决这一难题,Tang^[13]提出将混合鲸鱼优化算法(hybrid whale optimization algorithm,HWOA)应用于 WiFi 定位以提升其精度与稳定性;Liu^[14]提出基于多尺度主成分分析(multiscale principal component analysis,MSPCA)与图论时域卷积网络(graph temporal convolutional network,GTCN)的 WiFi 室内定位方法(MSPCA-GTCN);Wang^[15]提出一种基于随机森林(random forest,RF)算法进行接入点(access point,AP)选择、并运用冠豪刺猾优化器(crested porcupine optimizer,CPO)算法优化支持向量回归(support vector regression,SVR)的 WiFi 室内定位算法;蒲巧林等^[16]等提出了一种面向大场景 WLAN 室内定位的半张量压缩感知(semi-tensor product compressed sensing,STP-CS)方法,通过引入改进聚类算法进行粗定位以缩减搜索空间,并利用 STP-CS 技术对高维观测矩阵降维,在保证定位精度的同时显著降低了存储开销和计算复杂度。

针对上述 WiFi 定位方法存在的问题,为了能够在室内复杂环境中实现更高精度的定位,本文提出了融合 CNN 与 BiLSTM 的 RSSI 指纹定位算法。离线阶段通过室内采集点的 WiFi 的 RSSI 值,以此建立位置特征指纹库,对于原始 RSSI 数值通过高斯滤波去除指纹库中的高频噪声,保留信号整体趋势和特征,再通过卡尔曼滤波对信号进行动态估计与跟踪,以此实现对信号的滤波。将过滤后的信号输入神经网络内,利用 CNN-BiLSTM 网络对指纹库内数据进行训练;在线定位阶段将收到的信号输入指纹库以进行匹配,然后通过 CNN-BiLSTM 网络从而实现定位。通过 MATLAB 仿真部署 WiFi 基站进行数据采集以及实验后验证了算法对比其他定位方法的优越性。

1 基于位置指纹的定位原理

“位置指纹”把实际位置与某种“指纹”联系起来,一个位置对应一个指纹。该定位方法可划分为两个阶段:预先

构建指纹数据库的离线阶段以及利用当前观测数据进行位置预测的在线阶段,定位过程如图 1 所示。




图 1 CNN-BiLSTM 融合算法工作流程

Fig. 1 Workflow of the CNN-BiLSTM fusion localization algorithm

在离线阶段,通过在多个参考位置采集无线信号的 RSSI 数据,用于建立一个反映信号特征与空间坐标映射关系的指纹数据库。在环境中选择 N 个参考点 $[P_1, P_2, \dots, P_N]$, 每个点坐标即 $P_i = (x_i, y_i)$, 每个参考点采集来自 M 个 WiFi 的 AP 的 RSSI 值,形成 RSSI 向量,如式(1)所示。

$$\mathbf{f}_i = [r_{i1}, r_{i2}, \dots, r_{iM}] \quad (1)$$

其中, r_{im} 表示第 i 个点接收到第 M 个 AP 信号强度。对采集到的数据通过高斯滤波和卡尔曼滤波以平滑 RSSI 原始数据。首先采用一维高斯平滑滤波,参数为 9 点高斯核,标准差 $\sigma=1$ 。随后构建一维标量卡尔曼滤波器,对高斯平滑后的 RSSI 序列进行动态估计与跟踪,卡尔曼滤波参数设定为:状态转移矩阵 $\mathbf{F}=1$,观测矩阵 $\mathbf{H}=1$,过程噪声方差 $\mathbf{Q}=1 \times 10^{-3}$,观测噪声方差 $R=0.5$,初始协方差 $P_0=1$,初始状态由序列首个高斯平滑结果给定。以平滑后的 RSSI 数据构建位置指纹库,如式(2)所示。

$$\mathbf{D} = \{(\mathbf{f}_i, P_i)\}_{i=1}^N \quad (2)$$

式中: $\mathbf{D}$ 表示在 P_i 处测得的 RSSI 特征为 $\mathbf{f}_i$ 。

在线阶段即当用户处于未知位置时,通过采集当前位置的 RSSI,与指纹库数据进行匹配,推断当前坐标。欧氏距离、余弦相似度等指标已被用于信号比较。常用的方法包括 K 近邻(K-nearest neighbor,KNN)、加权 K 近邻(weight K-nearest neighbor,WKNN)、SVM、RF 等。微软在 2000 年最早进行 WiFi 指纹定位的研究工作,他们使用 RSSI 的 $\mathbf{r}$ 向量和指纹向量 $\mathbf{p}$ 的欧氏距离公式计算距离匹配指纹库内的欧氏距离来确定移动设备位置。假设指纹是 N 维的,即有 N 个可见的 AP, M 个网格点,欧氏距离定义

如式(3)所示。

$$D = \sqrt{\sum_{i=1}^N |r_i - p_i|^2} \quad (3)$$

2 CNN-BiLSTM 融合定位

2.1 CNN

CNN^[17]是一类用于处理网格状数据的深度学习网络结构,通过局部连接与权值共享进行层次化特征提取。其核心思想是通过局部连接、权值共享和层次化特征提取,自动学习输入数据的空间或时序局部模式^[18],其原理示意图如图 2 所示。




图 2 卷积神经网络示意图

Fig. 2 Schematic diagram of the convolutional neural network

CNN 的优势是提取能力强,它的卷积层能够自动学习数据中的空间特征,对于定位任务中的信号数据,卷积操作的局部感知特性使得 CNN 能够保留数据中的空间局部相关性,这在处理具有空间关联性的定位数据时很重要,有助于更准确地捕捉信号随空间位置的变化规律。假设输入矩阵大小为 w ,卷积核大小为 k ,步幅为 s ,补零层数为 p ,则卷积后特征大小如式(4)所示。

$$w' = \frac{w + 2p - k}{s} + 1 \quad (4)$$

本算法 CNN 层中设计 3 层 3×3 的卷积层,2 层 2×2 的池化层,最终输出尺寸为 $[1, 25, 32]$ 。通过展平层将三维输出拉平成一维向量,共 800 个特征。

2.2 BiLSTM

BiLSTM,由前向 LSTM 与后向 LSTM 组合而成。LSTM 模型是递归神经网络(recurrent neural network, RNN)的变体,都属于循环神经网络,能很好地处理长序列数据中固有的长期依赖特性^[19],但是它存在无法编码从后向前的信息的问题^[20],因此研究者们提出了 BiLSTM 方法。

BiLSTM 能够同时考虑序列数据的前后上下文信息,对于定位任务中可能存在的时序相关性(如移动设备的轨迹数据),可以更好地建模和利用这些时间序列信息,提高定位精度。BiLSTM 的门控机制使其能够有效地处理长序列数据中的长期依赖关系,避免了传统 RNN 中的梯度消失问题,能够更好地捕捉定位数据中的长期模式和趋势。BiLSTM 从两个方向(正向和反向)对序列数据进行处理,然后将两个方向的输出 $\vec{h}_L$ 和 $\overleftarrow{h}_R$ 进行融合,共同决定输出

的值 h_t ,原理图如图 3 所示,原理公式如式(5)所示。

$$\begin{cases} \vec{h}_{L_t} = \text{LSTM}(x_t, \vec{h}_{L(t-1)}) \\ \overleftarrow{h}_{R_t} = \text{LSTM}(x_t, \overleftarrow{h}_{R(t-1)}) \\ h_t = \vec{w}h_{L_t} + \overleftarrow{w}h_{R_t} + b_y \end{cases} \quad (5)$$




图 3 BiLSTM 原理示意图

Fig. 3 Schematic diagram of the bidirectional long short-term memory network

本算法中 BiLSTM 层设置隐状态维度为 256,在此层中将 CNN 层中输出的数据进行双向拼接得到长度为 512 的向量。在全连接层将数据映射到 2 个输出节点,即 (x, y) ,对应两个坐标预测值。

2.3 CNN-BiLSTM 模型

结合 CNN 与 BiLSTM 的优势,提出了 CNN-BiLSTM 融合神经网络来实现通过 WiFi 的指纹定位算法,其框架如图 4 所示。




图 4 CNN-BiLSTM 原理框架

Fig. 4 Framework of the cnn-bilstm fusion model

本算法中,对于经过 GS/KF 滤波的 RSSI 信号输入, CNN 首先对输入数据进行空间提取,然后通过展平(Flatten)层展平,接着 BiLSTM 层对特征序列进行时间序列处理,最后通过全连接层输出定位结果。

假设系统收集了连续 T 个时间步的 RSSI 向量,有来自 M 个 AP 的信号,经过滤波后输入 CNN 网络中尺寸如式(6)所示。CNN 作为特征提取器,用于学习 RSSI 向量在空间上的相关性,CNN 层经过卷积、池化、展平后输出可表示为:

$$F_{\text{CNN}} = \text{CNN}(\mathbf{R}) \in \mathbf{R}^{d \times T} \quad (6)$$

其中, d 表示每一时刻的空间特征维度。将 CNN 输出的时间序列特征作为 BiLSTM 层的输入。

$$\mathbf{H} = \text{BiLSTM}(F_{\text{CNN}}) \in \mathbf{R}^h \quad (7)$$

其中, $\mathbf{H}$ 表示正向与反向 LSTM 拼接的结果。最后在全连接层输出位置坐标。

$$\hat{\mathbf{P}} = \mathbf{W}\mathbf{H} + \mathbf{b} \in \mathbf{R}^2 \quad (8)$$

其中, $\hat{\mathbf{P}} = (x, y)$ 表示预测位置; $\mathbf{W}$ 、 $\mathbf{b}$ 是全连接层的参数。

CNN 的特征提取能力和 BiLSTM 的序列建模能力互补, 使得模型能够更好地适应不同的定位场景和数据分布, 提高了模型的泛化能力, 使其在各种实际环境下都能保持较好的定位性能。对于复杂的定位场景(如室内多路径效应、遮挡等情况), CNN-BiLSTM 模型能够更好地处理其中的复杂关系和不确定性, 通过学习到的丰富特征和序列模式, 更准确地估计目标位置。

3 实验结果与仿真分析

3.1 实验设置

为验证基于 CNN-BiLSTM 的 WiFi 指纹定位算法性能, 通过 MATLAB 仿真教室环境进行数据采集和实验。

仿真教室长 12 m, 宽 8 m, 以教室的西北角作为坐标原点建立坐标系, 在教室 4 个角落布置基站, 在室内 10 m × 6 m 范围内每隔 0.25 m 设置一个采样点, 如图 5 所示。设置模型标准差 std_var=0.3 dB, 此数值表示建模环境中的随机信号衰减, 如多径效应、障碍物等引起的波动; 设置参考距离接收功率为 -40 dBm, 此数值符合中等功率 AP; 设置路径损耗因子 $n=2.2$, 表示环境存在轻度遮挡; 对每个采样点进行 100 次独立 RSSI 测量, 模拟实际环境中多次采样取平均操作。




图 5 教室内采样点示意图

Fig. 5 Layout of sampling points in the simulated classroom environment

为全面评估改进模型(CNN-BiLSTM)在连续定位任务中的性能优势, 本文设计了一个严格的 Monte Carlo 随机轨迹验证实验。在每次实验中, 系统随机生成 100 条连续移动轨迹, 每条轨迹包含 200 个时间步, 其初始位置在室内区域 $[1.5, 10.5] \times [1.5, 6.5]$ 内均匀选取。初始移动速度 v_0 在区间 $[0.25 \text{ m/s}, 0.6 \text{ m/s}]$ 采样, 初始运动方向 θ_0 从 $[0, 2\pi]$ 均匀采样, 轨迹采样周期 $d_t=0.2 \text{ s}$ 。为模拟真实

行走轨迹中速度与方向的微扰, 采用如下随机更新模型:

$$\begin{cases} v_t = \text{clip}(v_{t-1} + \Delta v_t, 0.2, 0.6), \\ v_t \sim U(-0.02, 0.02) \\ \theta_t = \theta_{t-1} + \Delta \theta_t, \\ \Delta \theta_t \sim U(-0.08, 0.08) \text{ rad} \end{cases} \quad (9)$$

其中, 速度扰动 Δv_t 对应每步最大约 $\pm 0.02 \text{ m/s}$ 的波动, 方向扰动 $\Delta \theta_t$ 对应约为 $\pm 4.6^\circ$ 的转向变化。位置按照式(10)更新。

$$\mathbf{p}_t = \mathbf{p}_{t-1} + v_t d_t [\cos \theta_t, \sin \theta_t] \quad (10)$$

每个时间步根据设备与各基站的欧氏距离计算 RSSI 值。模型采用长度为 $\text{win}=5$ 的滑动窗口作为输入, 分别使用 CNN-LSTM 与 CNN-BiLSTM 网络进行定位预测, 最终计算每条轨迹的平均定位误差。

3.2 评价指标

本文选用评价室内定位算法性能的常用指标: 定位误差、平均定位误差、累积分布函数(cumulative distribution function, CDF)和均方根误差(root mean square error, RMSE)并通过实验获得参数对算法优越性进行验证。定位误差用于衡量预测位置与真实位置之间的偏差, 其通常通过计算两点间的欧氏距离来获得, 在指纹定位中常采用如式(11)所示。

$$\text{Error} = \sqrt{(x_t - x_0)^2 + (y_t - y_0)^2} \quad (11)$$

平均误差是对 n 次定位误差求取算术平均值, 如式(12)所示。

$$\text{Error}_{\text{avg}} = \frac{1}{n} \sum_{i=1}^n \text{Error}_i \quad (12)$$

CDF 用于衡量定位误差在不同阈值下的累计概率, 有助于从整体上分析定位算法的精度表现趋势, 其表达形式如式(13)所示。

$$P = P(x < x_0) \quad (13)$$

RMSE 用于衡量预测结果与实际值之间的平均偏差程度, 其定义为偏差平方的平均值开方, 对异常值具有较强的敏感性, 其计算公式如式(14)所示。

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - f(x_i))^2} \quad (14)$$

3.3 离线阶段对比

在离线阶段将本文提到的 CNN-BiLSTM 算法与 CNN 进行对比, 训练参数一致: 优化器选择 Adam, 设置最大训练轮次 80, 梯度裁剪阈值 1, 初始学习率 0.01, 学习率衰减周期 20, 衰减因子 0.2。其中 CNN 离线训练精度如图 6 所示, 其在 x 和 y 方向的预测值和真实值的相关系数如图 7(a)和(b)所示, 预测误差如图 7(c)所示; CNN-BiLSTM 离线训练精度如图 8 所示, 其在 x 和 y 方向的预测值和真实值的相关系数如图 9(a)和(b)所示, 预测误差如图 9(c)所示。

通过对比 CNN 和 CNN-BiLSTM 在离线状态训练的数据, 单独使用 CNN 定位, 训练时均方根误差在第 26 轮后




图 6 CNN 离线训练精度

Fig. 6 Offline training accuracy of the CNN model




图 7 CNN 离线训练结果

Fig. 7 CNN offline training results




图 8 CNN-BiLSTM 离线训练精度

Fig. 8 Offline training accuracy of the CNN-BiLSTM model




图 9 CNN-BiLSTM 离线训练结果

Fig. 9 CNN-BiLSTM training results

趋于稳定,稳定后均方根误差为 0.35 m,预测平均误差为 0.139 m,最大误差约为 0.455 m;CNN-BiLSTM 融合算法在第 23 轮后趋于稳定,稳定后均方根误差为 0.2 m,预测平均误差为 0.077 m,最大误差约为 0.249 m,表明 CNN-BiLSTM 融合算法在离线回归精度上优于单独使用 CNN 模型,基于图 6~9 中数据如表 1 所示。

表 1 离线消融实验两种算法对比

Table 1 Comparison of two models in offline ablation experiments

算法	稳定轮次	横坐标 相关 系数	纵坐标 相关 系数	稳定后 RMSE/ m	预测 误差 平均值/ m
CNN	26	0.999 3	0.999 5	0.35	0.139
CNN-BiLSTM	23	0.999 8	0.999 5	0.20	0.077

3.4 在线阶段对比

在设定的 20 个测试点上,本文将提出的 CNN-BiLSTM 算法与 CNN 算法、CNN-LSTM 算法以及传统回归算法:质心定位法(Centroid)、线性回归(liner regression,LR)、RF、梯度提升决策树(gradient boosting decision tree,GBDT)和 SVM 进行定位性能对比。从误差分布、平均误差和累积分布函数等多个角度进行分析如图 10 所示。




图 10 各种定位算法定位结果

Fig. 10 Localization results of various algorithms

图 10 是各种定位算法定位结果的箱式图,其中定位主要评价指标如表 2 所示。融入 BiLSTM 网络后定位算法的平均精度相比 CNN-LSTM 定位提高了 0.08 m。

为进一步评估各算法在室内实时定位场景中的应用性能,本文对 8 类算法的训练时间和单样本推理时间进行了统计。实验在同一硬件条件下进行(Intel i5 处理器、

表 2 各种定位算法的定位结果

Table 2 Localization performance of different algorithms (m)

方法	平均 误差	最大 误差	最小 误差	均方根 误差
Centroid	0.36	1.76	0.030	0.24
LR	0.30	1.62	0.010	0.24
RF	0.13	0.42	0.020	0.07
GBDT	0.34	1.32	0.010	0.24
SVM	0.38	0.91	0.050	0.14
CNN	0.17	0.43	0.007	0.08
CNN-LSTM	0.16	0.58	0.020	0.09
CNN-BiLSTM	0.08	0.21	0.003	0.04

16 GB 内存、MATLAB 2023b,无 GPU 加速)。结果如表 3 所示。

表 3 各算法训练时间与单样本推理时间对比

Table 3 Comparison of training time and single-sample inference time for various algorithms

方法	训练时间/s	推理时间/ms
Centroid	—	0.143
LR	0.466	0.570
RF	0.988	39.770
GBDT	2.359	47.669
SVM	0.222	0.674
CNN	12.098	4.794
CNN-LSTM	16.694	6.799
CNN-BiLSTM	18.930	15.266

在离线阶段中,传统的机器学习模型训练耗时明显低于深度学习模型,其中 LR、SVM 和 RF 训练时间均在 1 s 左右,GBDT 时间在 2.359 s。深度学习模型包含卷积核时序结构,训练时间相对较长,但是 CNN-BiLSTM 网络训练耗时介于 CNN 与 CNN-LSTM 之间,明显短于 CNN-LSTM 网络。

在在线阶段中,所有方法的单样本预测时间均远低于实时定位对 100~200 ms 的更新周期要求。在传统方法中,LR 与 SVM 的推理耗时不足 1 ms;RF 与 GBDT 推理时间较长,为 39.77 和 47.669 ms。深度学习网络中,CNN 的推理时间最快,为 4.794 ms,CNN-LSTM 为 6.799 ms,而 CNN-BiLSTM 的推理时间为 15.266 ms。尽管预测开销高于其他深度学习模型,但推理速度仍处于毫秒级,能够满足应用需求。

对应的误差 CDF,用以衡量不同算法在误差阈值内的

准确率如图 11 所示。CNN-BiLSTM 相比另外 3 个算法都更靠左且更陡,说明大多数点的误差较小且分散度小,算法精度更高、更稳定。




图 11 各种算法的累积分布函数

Fig. 11 Cumulative distribution functions of different localization algorithms

100 条随机轨迹的平均误差分布如图 12 所示,其中空心圆表示 CNN-LSTM,叉号表示 CNN-BiLSTM。可以观察到,绝大多数轨迹的 BiLSTM 误差低于 LSTM,表明其在连续时间序列建模上具有更强的稳定性和泛化能力。




图 12 Monte Carlo 随机轨迹验证实验结果

Fig. 12 Results of Monte Carlo trajectory-based continuous localization experiment

图 13 为随机轨迹验证实验误差分布直方图,纵坐标概率密度函数(probability density function, PDF)用于反映模型在整体样本上的性能稳定性。进一步表明,BiLSTM 模型的误差分布更集中,右尾更短,表明其在复杂 RSS 波动下具有更好的鲁棒性。随机轨迹验证实验误差定量结果如表 4 所示。




图 13 Monte Carlo 随机轨迹验证实验误差分布直方图

Fig. 13 Error distribution histograms of the Monte Carlo trajectory validation

表 4 Monte Carlo 随机轨迹验证实验定量结果

Table 4 Quantitative results of the Monte Carlo trajectory validation experiment (m)

方法	平均误差
CNN-LSTM	1.246 ± 0.320
CNN-BiLSTM	1.026 ± 0.330

4 结 论

本文提出并验证了一种基于 CNN 与 BiLSTM 融合的 RSSI 指纹定位方法,旨在缓解复杂室内环境中多路径效应与信号遮挡对回归定位精度的影响。方法上,利用卷积网络提取 RSSI 的空间特征,采用双向 LSTM 捕获序列的双向时序依赖,并在数据预处理上引入双重滤波以抑制瞬态噪声。为全面评估方法性能,本文在 MATLAB 仿真平台上与多种基线方法(CNN、CNN-LSTM、线性回归、RF、GBDT、SVM 等)进行了比较,并设计了两类实验:随机点定位测试与 Monte Carlo 随机轨迹的连续定位验证。

实验结果表明,在随机点定位测试中,本文所提 CNN-BiLSTM 模型在平均误差、最大误差与误差标准差上均显著优于对比方法。相较于 CNN-LSTM,平均误差下降约 52.1%,最大误差下降约 53.2%,标准差下降约 55.6%。在连续轨迹的 Monte Carlo 验证中,CNN-BiLSTM 在平均轨迹误差上也显著优于 CNN-LSTM,且误差分布更集中、右尾更短,说明其在在线连续定位场景中具有更好的稳定性与鲁棒性。

参考文献

[1] 王慧强,高凯旋,吕宏武. 高精度室内定位研究评述及未来演进展望[J]. 通信学报, 2021, 42(7): 198-210.
WANG H Q, GAO K X, LYU H W. Review and future

- evolution of high-precision indoor positioning[J]. Journal on Communications, 2021, 42(7): 198-210.
- [2] 贺卓悦,王伟,刘杰,等. 基于 WiFi 的混合稳健 AP 定位技术研究[J]. 电子测量技术, 2026, 49(3): 155-164.
HE ZH Y, WANG W, LIU J, et al. Research on hybrid robust AP localization technology based on WiFi [J]. Electronic Measurement Technology, 2026, 49(3): 155-164.
- [3] 乔寅嵩,张大龙,韩刚涛,等. 基于深度神经网络的室内定位算法[J]. 传感器与微系统, 2024, 43(6): 125-128.
QIAO Y S, ZHANG D L, HAN G T, et al. Indoor positioning algorithm based on deep neural networks[J]. Sensors & Microsystems, 2024, 43(6): 125-128.
- [4] 庄宇峰,霍政界,黄申茂,等. 复杂环境下基于边缘计算的 RFID 相控阵定位方法[J]. 电子测量技术, 2025, 48(17): 125-131.
ZHUANG Y F, HUO ZH J, HUANG SH M, et al. RFID phased-array localization method based on edge computing in complex environments [J]. Electronic Measurement Technology, 2025, 48(17): 125-131.
- [5] 陈帅印,刘宁,胡可君. 一种抗差估计的 GNSS/UWB/IMU 集成式室内外无缝定位方法[J]. 电子测量技术, 2025, 48(5): 74-80.
CHEN SH Y, LIU N, HU K J. A robust estimation-based GNSS/UWB/IMU integrated indoor-outdoor seamless positioning method[J]. Electronic Measurement Technology, 2025, 48(5): 74-80.
- [6] 刘伟,李艾龙,李卓,等. 基于改进灰狼算法优化 BP 神经网络的 RSS 指纹定位[J]. 电子测量技术, 2025, 48(14): 162-175.
LIU W, LI AI L, LI ZH, et al. RSS fingerprint localization based on BP neural network optimized by an improved grey wolf optimizer [J]. Electronic Measurement Technology, 2025, 48(14): 162-175.
- [7] 蔡庸辉,周凌柯,李胜,等. 基于 SINS/GNSS 动态差分序列的 AEKF 算法研究[J]. 电子测量技术, 2024, 47(19): 44-53.
CAI Y H, ZHOU L K, LI SH, et al. Research on the AEKF algorithm based on SINS/GNSS dynamic differential sequence [J]. Electronic Measurement Technology, 2024, 47(19): 44-53.
- [8] 余晴,江金光,谢东朋,等. 基于 LSTM 场景分类的行人自适应低功耗定位方案[J]. 计算机与现代化, 2025(2): 44.
YU Q, JIANG J G, XIE D P, et al. Pedestrian adaptive low-power positioning scheme based on LSTM scene classification [J]. Computer and Modernization, 2025(2): 44.
- [9] 彭铎,查海音,曹坚,等. 基于 CNN-LSTM 声速预测的水下移动节点定位算法[J]. 电子测量与仪器学报, 2024, 38(11): 146-157.
PENG D, ZHA H Y, CAO J, et al. Underwater mobile node localization algorithm based on CNN-LSTM sound velocity prediction [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(11): 146-157.
- [10] 吴仕勋,曾鑫睿,徐凯,等. 基于 LCVAE-CNN 的多任务室内 WiFi 指纹定位方法[J]. 计算机应用研究, 2025, 42(6): 1844-1851.
WU SH X, ZENG X R, XU K, et al. Multi-task indoor WiFi fingerprint localization method based on LCVAE-CNN[J]. Application Research of Computers, 2025, 42(6): 1844-1851.
- [11] LI J L, LIU S L, GAO Y P, et al. UWB(N) LOS identification based on deep learning and transfer learning[J]. IEEE Communications Letters, 2024, 28(9): 2111-2115.
- [12] 王开亮,谢亚琴,宦海,等. 基于投票机制的室内 WiFi 指纹定位算法[J]. 电子测量技术, 2023, 46(12): 61-68.
WANG K L, XIE Y Q, HUAN H, et al. Indoor WiFi fingerprinting localization algorithm based on voting mechanism [J]. Electronic Measurement Technology, 2023, 46(12): 61-68.
- [13] TANG CH J, SUN W, ZHANG X, et al. A sequential-multi-decision scheme for WiFi localization using vision-based refinement[J]. IEEE Transactions on Mobile Computing, 2023, 23(3): 2321-2336.
- [14] LIU X, WU R H, ZHANG H M, et al. Graph temporal convolution network-based wifi indoor localization using fine-grained csi fingerprint[J]. IEEE Sensors Journal, 2025, 25(5): 9019-9033.
- [15] WANG Y CH, XUE CH L, XIA Y, et al. RF-CPO-SVR algorithm for indoor localization based on wifi fingerprints[J]. Measurement Science and Technology, 2025, 36(3): 036309.
- [16] 蒲巧林,周龙璨,周牧,等. 基于半张量积压缩感知的室内定位算法[J]. 仪器仪表学报, 2024, 45(12): 329-339.
PU Q L, ZHOU L C, ZHOU M, et al. Indoor localization algorithm based on semi-tensor product compressed sensing[J]. Chinese Journal of Scientific Instrument, 2024, 45(12): 329-339.
- [17] 李彦冬,郝宗波,雷航. 卷积神经网络研究综述[J]. 计算机应用, 2016, 36(9): 2508-2515, 2565.
LI Y D, HAO Z B, LEI H. Review on convolutional neural networks[J]. Journal of Computer Applications, 2016, 36(9): 2508-2515, 2565.
- [18] 周飞燕,金林鹏,董军. 卷积神经网络研究综述[J]. 计算机学报, 2017, 40(6): 1229-1251.
ZHOU F Y, JIN L P, DONG J. A survey of convolutional neural networks[J]. Chinese Journal of Computers, 2017, 40(6): 1229-1251.
- [19] 高芷蓉,杨杉,喻希,等. 基于 CNN-BiLSTM-Attention 的电力系统虚假数据注入攻击检测[J]. 智慧电力, 2025, 53(4): 103-111.
GAO ZH R, YANG SH, YU X, et al. False data injection attack detection in power systems based on CNN-BiLSTM-Attention [J]. Intelligent Electricity, 2025, 53(4): 103-111.
- [20] SIAMI-NAMINI S, TAVAKOLI N, NAMIN A S. The performance of LSTM and BiLSTM in forecasting time series[C]//2019 IEEE International Conference On Big Data (Big Data), 2019: 3285-3292.

作者简介

孙浩, 硕士研究生, 主要研究方向为室内定位技术、无人系统 SLAM。

E-mail: 2023020055@bistu.edu.cn

谷玉海(通信作者), 博士, 研究员, 主要研究方向为测控技术及仪器。

E-mail: guyuhai@bistu.edu.cn