

文章编号: 1002-1582(2026)04-0473-08

考虑接收机姿态的双ELM室内可见光定位方法

窦道飞^{1,2*}, 张素阳^{3,4}

(1. 中国铁道科学研究院集团有限公司 通信信号研究所, 北京 100081)

(2. 国家铁路智能运输系统工程技术研究中心, 北京 100081)

(3. 国铁通信信号(北京)有限公司, 北京 100081)

(4. 通信信号基础设施智能运维铁路行业工程研究中心, 北京 100081)

摘 要: 针对接收机姿态动态变化引发接收信号特征畸变, 导致室内可见光定位精度下降的问题, 提出一种全局ELM(极限学习机)粗略定位与局部ELM精确定位相结合的室内可见光定位方法。首先, 将接收信号强度与接收机姿态信息作为联合指纹特征, 建立指纹特征与物理位置之间的映射关系, 离线构建全局指纹数据库; 然后, 利用全局指纹数据库训练全局ELM模型, 粗略确定待测接收机位置; 接着, 筛选指纹样本, 自适应构建局部指纹数据库, 并结合接收机实时姿态信息, 对局部指纹数据进行方向一致性校正与更新; 最后, 利用局部指纹数据库训练局部ELM模型, 实现在线精确定位。实验结果表明, 所提方法在维持较高计算效率的同时, 增强了接收机姿态变化的适应能力, 可为室内可见光定位提供一种定位精度高、鲁棒性强的参考方案。

关 键 词: 可见光定位; 极限学习机; 指纹数据库; 接收机姿态; 神经网络

中图分类号: TP394.1; TH691.9

文献标识码: A

Indoor visible light positioning based on dual ELM considering receiver orientation

DOU Daofei^{1,2*}, ZHANG Suyang^{3,4}

(1. Signal & Communication Research Institute, China Academy of Railway Sciences Group Co., Ltd, Beijing 100081, China)

(2. The Center of National Railway Intelligent Transportation System Engineering and Technology, Beijing 100081, China)

(3. China Railway Communication & Signal (Beijing) Co., Ltd, Beijing 100081, China)

(4. Railway Industry Engineering Research Center for Intelligent Operation and Maintenance of Communication & Signaling Infrastructure, Beijing 100081, China)

Abstract: To solve the problem of accuracy decline of indoor visible light positioning resulting from the distortion of received signal characteristics with dynamic changes of receiver orientation, a practical approach to indoor visible light positioning has been proposed, which combines the global ELM (extreme learning machine) for approximate positioning with local ELM for precise positioning. Firstly, received signal strength and receiver orientation information are used as joint fingerprint features to establish the mapping relationship between fingerprint features and physical position, and a global fingerprint database is constructed offline. Then, the global fingerprint database is adopted to train the global ELM model to roughly determine the position of the receiver under test. Next, fingerprint samples are selected to adaptively construct the local fingerprint database, which is calibrated and updated for direction consistency using the real-time information of receiver orientation. Finally, the local fingerprint database is utilized to train the local ELM model to achieve the online precise position information. Experimental results demonstrate that the proposed method not only maintains high computational efficiency but also en-

收稿日期: 2026-04-10; 收到修改稿日期: 2026-05-14

基金项目: 国家铁路智能运输系统工程技术研究中心开放课题 (RITS2025KF08)

作者简介: 窦道飞 (1977—), 男, 副研究员, 从事轨道交通信号系统安全测试的研究。

* 通讯作者: doudaofei_CARS@163.com

hances the adaptability to the variation of receiver orientation, which can provide a highly accurate and strongly robust reference solution for indoor visible light positioning.

Keywords: visible light positioning; extreme learning machine; fingerprint database; receiver orientation; neural network

0 引言

随着移动互联网、物联网、智能交通、智慧城市等产业的快速发展,基于位置的服务(Location-Based Services, LBS)已成为数字社会的重要基础服务,用户对定位服务的覆盖范围、精度和可靠性要求越来越高^[1]。目前,室内定位技术主要包括无线局域网(Wireless Local Area Networks, WLAN)、低功耗蓝牙(Bluetooth Low Energy, BLE)、射频识别(Radio Frequency Identification, RFID)、超宽带(Ultra-Wideband, UWB)等,然而以上技术仍存在明显缺陷,如WLAN定位易受外界信号干扰,其平均定位误差甚至高达2m;BLE易受环境噪声干扰,在复杂室内场景下定位稳定性较差;RFID技术有效定位距离有限,且定位误差较大;UWB定位虽在精度上表现突出,但需要部署大量专用设备,整体成本偏高^[2-5]。因此,亟需寻找精度更高、成本更低、抗干扰能力更强的室内定位技术。以发光二极管(Light Emitting Diode, LED)为信号发射源的可见光定位(Visible Light Position, VLP)技术具有带宽充足、定位精度高、保密性好、抗电磁干扰、绿色节能等优势^[6-8],已成为现阶段室内定位领域的研究热点。

采用指纹特征的室内VLP通过实时采集待测区域的信号特征参数,并与预先构建的离线指纹库进行特征匹配,进而实现目标位置估计^[9,10]。离线指纹库通常由各参考指纹点接收的VLP信号特征构成,主要包括接收信号强度(Received Signal Strength, RSS)、到达角、到达时间以及到达时间差等多维特征。在位置匹配阶段,常借助机器学习算法实现,典型方法包括 k 近邻(K-Nearest Neighbor, KNN)算法和神经网络等^[11,12]。其中,基于RSS的指纹定位法因实现简便、定位精度高、部署成本低等优势,成为该领域的主流研究方向之一。文献[13]针对支持向量机(Support Vector Machine, SVM)核函数参数与惩罚因子难以人工确定的问题,提出基于RSS指纹的定位方法,采用网格搜索算法优化SVM模型,定位精度可达0.042m。文献[14]提出了基于极限学习机(Extreme Learning Machine, ELM)神经网络的定位方法,分别采用遗传算法、麻雀搜索算法等对ELM网络的输入权重矩阵与隐含层偏置进行优化,平均定位误差低至1.73cm,且有效提高了定位实时性。

文献[15]将深度学习与RSS滤波相结合,提高了室内三维系统中VLP的准确率与稳定性。文献[16]提出了一种自适应加权 k 近邻(Weighted K-Nearest Neighbor, WKNN)算法,动态筛选可靠的参考节点并优化其数量,在稀疏指纹库场景下表现出良好的鲁棒性。文献[17]提出了一种基于RSS指纹自迁移学习的倾斜弹性定位方法,以解决室内VLP系统因倾斜接收导致的匹配失效问题,提升其实际应用的可靠性。上述基于RSS的VLP研究虽在定位精度方面取得较大进展,但大多集中于模型结构与算法优化,较少考虑接收机姿态动态变化对接收信号特征的影响,难以同时兼顾、定位精度、姿态鲁棒性与计算效率;同时,传统指纹库构建多为静态,难以适应接收机姿态多变的实际场景,导致定位精度与鲁棒性不高。

为了进一步降低室内VLP过程中接收机姿态变化对定位结果的影响,提出一种基于自适应局部指纹库的双ELM可见光定位方法,在离线阶段融合接收机随机姿态信息构建全局指纹库;在线阶段通过双ELM依次完成粗略定位与自适应局部指纹库生成,并结合实时姿态对局部指纹库进行动态校正与更新,最终实现高精度定位,有效提升接收机姿态动态变化场景下室内定位的精度与鲁棒性。

1 基本原理

室内VLP系统主要由发射机LED光源、可见光信道和接收机光电探测器(Photodiode, PD)组成,如图1所示。




图1 VLP信道视距链路传输模型

发射机LED光源服从朗伯辐射模型,由于视场角(Field of View, FOV)限制,当入射角小于视场角的时候,PD才能有效接收信号,因此在视距(Line-of-Sight, LOS)链路条件下,信道增益可表示为

$$H_L = \frac{(m+1)A}{2\pi D_d^2} \cos^m \varphi \cdot \cos \psi \cdot T_s(\psi) g(\psi) \quad (1)$$

式中, m 为朗伯辐射阶数; A 为PD的有效接收面积; D_d 为LED与PD间的直线距离; φ 为LED的辐射角; ψ 为PD的入射角; $T_s(\psi)$ 为光学滤波器增益; $g(\psi)$ 为聚光器增益。

朗伯辐射阶数 m 由LED半功率角 $\Phi_{1/2}$ 决定, 可表示为

$$m = -\frac{\ln 2}{\ln(\cos \Phi_{1/2})} \quad (2)$$

聚光器增益 $g(\psi)$ 由聚光器折射率 v 和最大视场角 Ψ_c 决定, 可表示为

$$g(\psi) = \begin{cases} \frac{v^2}{\sin^2 \Psi_c}, & 0 \leq \psi \leq \Psi_c \\ 0, & \psi > \Psi_c \end{cases} \quad (3)$$

在VLP系统中, PD噪声 N_n 主要包括散粒噪声与热噪声, 可将其建模成高斯白噪声。

因此, PD接收光功率 P_r 可表示为

$$P_r = H_L \cdot P_t + N_n \quad (4)$$

式中, P_t 为LED发射功率。

2 自适应局部指纹库双ELM定位方法

所提双ELM室内VLP方法在离线训练阶段, 联合PD姿态与RSS构建全局指纹库, 训练全局ELM模型。在线阶段先完成初始粗略定位, 再修正局部指纹, 最终通过局部ELM模型实现精确定位。

2.1 离线训练阶段

室内VLP系统的定位场景为长、宽、高分别为 L 、 W 、 H 的长方体空间, M 个LED光源均匀部署在天花板上, 第 k 个LED光源的空间坐标为 $z_k = (x_k, y_k, H)$; PD位于距离地面高度 h 的水平接收面, 系统有效定位区域为 $R = [0, L] \times [0, W]$ 。采用步长 Δs 的均匀网格对平面 R 进行采样, 沿 x 、 y 轴的采样间隔数分别为 P 、 Q , 最终得到总数量为 $N_g = (P+1)(Q+1)$ 的参考点, 所有参考点构成网格集合 P , 用于全局指纹库的构建, 室内可见光指纹定位模型如图2所示。




图2 室内可见光指纹定位模型

对于全局指纹库中第 i ($1 \leq i \leq N_g$) 个参考点, 其空间坐标为 (x_i, y_i, h) , PD接收面的真实姿态向量为 $(n_{(x,i)}, n_{(y,i)}, n_{(z,i)})$, 为模拟惯性测量单元 (Inertial

Measurement Unit, IMU) 的实际测量误差, 引入标准差为 σ_θ 的高斯角度扰动, 得到带噪声的姿态测量值 $(\hat{n}_{(x,i)}, \hat{n}_{(y,i)}, \hat{n}_{(z,i)})$, 由PD得到该点对第 k 个LED光源的光接收功率 $P_{(k,i)}$ 。

由真实位置、法向量及接收功率特征共同构成的 N_g 个指纹信息, 构建用于模型训练的全局指纹库 D_g , 则

$$\begin{cases} D_g = \{F_i | i = 1, 2, \dots, N_g\} \\ F_i = (x_i, y_i, \hat{n}_{(x,i)}, \hat{n}_{(y,i)}, \hat{n}_{(z,i)}, P_{(1,i)}, P_{(2,i)}, \dots, P_{(k,i)}) \end{cases} \quad (5)$$

2.2 在线定位阶段

ELM采用单层前馈神经网络架构, 其隐藏层权重和阈值采用随机初始化, 无需迭代更新, 输出层权重通过最小二乘法求解, 从而在保持回归预测精度的同时显著降低训练计算量, ELM整体网络结构如图3所示。




图3 ELM网络结构

假设给定ELM神经网络的 N 个训练样本为 $\{(X_i, Y_i)\}_{i=1}^N$, 输入向量为 $X_i = [x_{i1}, x_{i2}, \dots, x_{in}] \in \mathbf{R}^n$, 则对应的期望输出为 $Y_i = [y_{i1}, y_{i2}, \dots, y_{it}] \in \mathbf{R}^t$ 。若该网络的输入神经元数量为 n , 输出神经元数量为 t , 则有 l 个隐藏层节点的单隐层神经网络可表示为

$$f(X_i) = \sum_{j=1}^l \beta_j g(W_j^T X_i + b_j) \quad (6)$$

式中, β_j 为第 j 隐层节点到输出层的输出权值; $g(\cdot)$ 表示隐藏层激活函数; W_j 为第 j 隐层节点的输入权值; b_j 为第 j 隐层节点的偏置。

式 (6) 可以表示为矩阵形式

$$H\beta = Y \quad (7)$$

式中, H 为神经网络隐藏层的输出矩阵。输出权值矩阵 β 可通过求解式范数最小化问题得到

$$\hat{\beta} = \arg \min_{\beta} \|H\beta - Y\| \quad (8)$$

式中, $\|\cdot\|$ 为范数, Y 表示期望输出。因此, 输出权值矩阵可表示为

$$\hat{\beta} = H^+ Y \quad (9)$$

式中, H^+ 表示隐藏层输出矩阵 H 的伪逆。

基于上述基础模型, 分别构建全局ELM与自

适应局部 ELM 两个子模型, 通过两级协同实现高精度定位。

以全局指纹库 D_g 为训练集, 训练全局 ELM 网络, 构建输入特征空间与二维空间坐标之间的非线性映射关系, 可表示为

$$\begin{cases} f_g: \mathbf{X}^{(g)} \rightarrow (x, y) \\ \mathbf{X}^{(g)} = (\hat{n}_{(x,i)}, \hat{n}_{(y,i)}, \hat{n}_{(z,i)}, P_{(1,i)}, P_{(2,i)}, \dots, P_{(k,i)}) \end{cases} \quad (10)$$

式中, $\mathbf{X}^{(g)}$ 为全局 ELM 的输入向量, $f_g(\cdot)$ 表示全局 ELM 的激活函数。那么, 测试点估计的初始位置为

$$(\hat{x}^{(g)}, \hat{y}^{(g)}) = f_g(\mathbf{X}^{(g)}) \quad (11)$$

针对全局 ELM 在局部区域拟合能力不足的问题, 设计一种基于自适应局部指纹库的精确定位方法。该方法以全局粗略定位结果为中心, 仅在有限空间范围内重新建立位置与功率特征之间的映射关系, 从而显著提升定位精度。

以全局 ELM 输出的粗略定位结果 $(\hat{x}^{(g)}, \hat{y}^{(g)})$ 为圆心, 设定局部搜索半径 r_l , 在全局指纹库中筛选满足以下欧氏距离约束的样本的 e 个样本共同构成局部指纹子库 D_l

$$D_l = \left\{ F_e \mid \sqrt{(x_e - \hat{x}^{(g)})^2 + (y_e - \hat{y}^{(g)})^2} \leq r_l \right\} \quad (12)$$

为保证局部库的样本数量合理性, 设置样本数上下限 $N_{\min} < |D_l| < N_{\max}$, 其中 $N_{\min}$ 和 $N_{\max}$ 分别为局部指纹库最小和最大样本数。

离线指纹样本的接收方向与在线测试点的实时方向往往存在差异, 为减弱 PD 姿态不一致对功率特征的影响, 利用测试点的姿态信息对局部样本的接收光功率进行一致性更新, 使局部指纹在方向维度上与测试点保持一致, 从而增强局部样本与测试点之间的特征匹配度。

方向一致性更新后的新功率可表示为

$$P'_{(a,i)} = P_{(a,i)} \cdot \frac{\cos \psi_{(a,t)}}{\cos \psi_{(a,i)}} \quad (13)$$

式中, $\cos \psi_{(a,i)}$ 为局部样本 i 相对于第 a 个 LED 光源的入射余角; $\cos \psi_{(a,t)}$ 为测试点相对于第 a 个 LED 光源的入射余角; $P_{(a,i)}$ 为方向一致性更新前的功率。

噪声会导致接收功率测量值存在小幅扰动。但由于所提校正方法为入射余角的比值校正, 噪声为加性高斯白噪声, 对功率比值的影响较小。所提方法通过全局 ELM 粗定位已将待测点锁定在小范围区域, 避免了大范围内入射角变化导致的噪声放大, 可有效逼近理想姿态归一化效果。

更新后的局部接收功率特征作为输入, 重新训练一个轻量级局部 ELM 模型, 学习局部区域内功率特征与位置坐标之间的映射关系为

$$\begin{cases} f_l: \mathbf{X}^{(l)} \rightarrow (x, y) \\ \mathbf{X}^{(l)} = (P'_{(1,i)}, P'_{(2,i)}, \dots, P'_{(k,i)}) \end{cases} \quad (14)$$

那么, 由局部 ELM 输出精确定位结果为

$$(\hat{x}^{(l)}, \hat{y}^{(l)}) = f_l(\mathbf{X}^{(l)}) \quad (15)$$

经方向一致性校正, 局部样本点已归一化至与测试点一致的姿态, 姿态对 RSS 的畸变影响已被消除。此时局部 ELM 的输入为姿态解耦后的 RSS 特征, 无需额外输入姿态信息即可拟合位置映射关系; 且其仅在有限空间内回归, 非线性映射复杂度更低, 对残余姿态误差与噪声扰动的鲁棒性显著增强。因此, 局部 ELM 能够有效修正全局粗略定位结果, 实现高精度定位。

粗略定位阶段仅需实现大范围区域筛选, 对姿态误差容忍度较高, 无需执行角度校准即可满足要求, 若在此阶段引入角度校准, 将导致在线计算量激增。局部精确定位阶段通过角度校准策略, 在小样本集上执行, 计算量低且校准精度更高。系统将局部 ELM 的预测结果 $(\hat{x}^{(l)}, \hat{y}^{(l)})$ 作为测试点的位置估计, 自适应局部指纹库双 ELM 方法定位流程如图 4 所示。




图 4 自适应局部指纹库双 ELM 定位流程

3 实验结果及分析

3.1 实验参数设置

为验证双 ELM 定位方法的有效性, 室内 VLP 仿真系统关键参数设置如表 1 所示。分析 PD 姿态变化对接收信号特性的影响, 验证所提方法中不同参数对定位精度的影响; 通过消融实验及与多种算法对比, 综合评估所提方法在定位精度、鲁棒性与实时性方面的性能。

离线训练阶段: 4 个 LED 光源均匀分布在天花板上, 其坐标分别为 (1.25 m, 1.25 m, 3 m)、(1.25 m, 3.75 m, 3 m)、(3.75 m, 1.25 m, 3 m) 和 (3.75 m, 3.75 m, 3 m), 并在房间地面平面 $h=0$





图5 室内VLP仿真
场景与指纹点分布



(a) PD无倾斜
(b) PD倾斜45°
图6 不同PD姿态下4个LED光源总接收功率空间分布

处按照固定间隔均匀采样，如图5所示。考虑到实际应用中移动终端在运行过程中存在姿态扰动，在每个采样点处，记录来自4个LED光源的接收功率，同时保存对应的PD的姿态及位置坐标。设置采样间隔为0.2 m，在整个区域内共生成676个参考指纹点。

表1 仿真参数设置

参数	取值
房间尺寸($L \times W \times H$)/m ³	$5.0 \times 5.0 \times 3.0$
LED光源功率 P_i /W	2
PD视场角 Ψ_c /°	80
PD有效接收面积 A /cm ²	1
光学滤波器增益 $T_s(\psi)$	1
聚光器增益 $g(\psi)$	1
指纹采样间隔 Δs /m	0.2
测试点数量 S	500
局部指纹库初始半径 r_i /m	1
局部指纹库最小点数 $N_{\min}$	5
局部指纹库最大点数 $N_{\max}$	100

在线定位阶段：在接收平面内，随机生成 S 个测试点，通过计算各测试点的真实位置与估计位置间的均方根误差，对定位精度进行定量评估，即

$$\text{RMSE} = \sqrt{\frac{1}{S} \sum_{i=1}^S [(\hat{x}_i - x_i)^2 + (\hat{y}_i - y_i)^2]} \quad (16)$$

式中， (x_i, y_i) 和 $(\hat{x}_i, \hat{y}_i)$ 分别是第 i 个测试点的真实位置和估计位置。

3.2 PD姿态对接收功率的影响分析

针对PD姿态对接收功率的影响，对比分析PD水平无倾斜、沿 y 轴正向倾斜45°两种姿态下，房间内4个LED光源总接收功率的空间分布。PD倾斜

会造成接收功率分布显著畸变，影响指纹定位的固有映射关系，最终导致定位精度下降，如图6所示。

3.3 双ELM定位结果分析

围绕所提双ELM室内VLP方法，实验部分主要从参数敏感性、关键机制、定位性能等多个方面展开分析。

采用控制变量法，分别分析局部指纹库半径、最小局部指纹点数和最大局部指纹点数3个关键参数对定位精度的影响。在局部半径实验中，最小局部指纹点数和最大局部指纹点数分别固定为5和100，ELM神经元数量固定为100；在最小局部指纹点数和最大局部指纹点数实验中，局部指纹库半径固定为1.0m，ELM神经元数量固定为100。由图7(a)可知，当局部指纹库半径较小时，样本数量不足，局部ELM难以建立稳定回归模型，定位误差显著增大；随着半径增大，定位精度明显提升。由图7(b)和图7(c)可以看出，最小与最大局部指纹点数对定位性能起到约束作用。需要注意的是，图7(b)中RMSE随最小局部指纹点数变化存在一定波动。这主要是由于局部样本数量、样本空间分布及ELM随机初始化共同影响所致：样本过少时模型拟合稳定性不足；样本增加时，可能引入位置、姿态或RSS特征差异较大的指纹点，降低局部一致性；同时，ELM输入权重和隐含层偏置随机生成，在局部小样本条件下会放大误差波动。因此，最小局部指纹点数并非越大越好，应综合样本充足性、局部一致性和模型稳定性进行选取。本文将最小局部指纹点数设置为5。总体而言，局部ELM在各参数条件下




图7 不同参数下双ELM室内VLP误差比较

均优于全局 ELM，验证了双 ELM 框架在定位精度与鲁棒性层面的优势。

为分析 ELM 隐藏层神经元数量对定位性能的影响，在保持其他参数不变的条件下，改变 ELM 隐藏层神经元数量，并分别统计全局 ELM 和局部 ELM 的定位误差。由图 8 可知，当隐藏层神经元数量较少时，全局 ELM 的定位误差较大；随着神经元数量增加，全局 ELM 的 RMSE 明显下降，并逐渐趋于稳定。相比之下，局部 ELM 的最终定位误差始终低于全局 ELM 初始估计误差，说明局部指纹库能够有效改善全局粗定位结果。此外，当隐藏层神经元数量达到 100 后，局部 ELM 的 RMSE 变化幅度较小，表明该参数对局部 ELM 定位性能的影响相对有限。因此，本文将 ELM 隐藏层神经元数量统一设置为 100，以兼顾定位精度、模型复杂度和局部小样本条件下的稳定性。




图 8 ELM 隐藏层神经元数量对定位性能的影响

针对所提自适应局部双 ELM 方法中的关键机制，设置全局 ELM、固定局部 ELM、自适应局部无方向更新 ELM 和自适应局部双 ELM 方法 4 种消融配置进行比较。其中，全局 ELM 采用全局指纹库进行训练，固定局部 ELM 采用房间 1/4 区域的指纹库进行训练，自适应局部指纹库无方向更新 ELM 仅保留自适应局部建库机制，而所提方法同时引入自适应局部指纹库与方向更新机制。需要说明的是，仿真与硬件实验中的 KNN、WKNN、MLP 和全局 ELM 等基线方法均未采用式 (13) 进行方向一致性校正，式 (13) 仅用于所提自适应局部双 ELM 方法的局部指纹库更新阶段，以便单独评估方向更新机制对定位性能的贡献。为直观比较不同消融配置的误差分布，绘制定位误差累积分布函数，如图 9 所示；同时，为进一步量化各模块对定位性能的影响，统计不同方法的 RMSE、平均误差、中位误差、最大定位误差以及误差 e_0 不超过 46.7cm 的累计概率，结果如表 2 所示。

由图 9 和表 2 可知，当定位误差阈值取 46.7 cm 时，所提方法的累计概率达到 99.2%，而全局 ELM、固定局部 ELM 和自适应局部无方向更新 ELM 的累计概率分别为 86.2%、54.6% 和 58.3%。

相较于上述三种方法，所提方法的累计概率分别提高 13.0%、44.6% 和 40.9%。结合表 2 可知，仅采用固定局部建库或自适应局部建库但不进行方向校正时，RMSE 和最大误差较大，说明姿态不一致会导致局部 RSS 指纹失配并产生长尾误差。引入方向一致性校正后，自适应局部双 ELM 的 RMSE 降至 15.55 cm，中位误差降至 9.09 cm，表明自适应局部建库与方向一致性校正共同作用后，能够显著提升定位精度与鲁棒性。




图 9 不同消融配置下定位误差的累积分布函数对比

表 2 不同消融配置下定位误差量化对比

方法	RMSE	平均 误差	中位 误差	最大 误差	$P(e_0 \leq 46.7)$
全局 ELM	35.23	28.79	24.22	139.63	0.862
固定局部 ELM	329.77	101.58	41.25	615.75	0.546
自适应局部 无方向更新 ELM	376.80	96.36	37.19	732.17	0.583
自适应局部 双 ELM	15.55	11.39	9.09	119.98	0.992

为全面评估定位性能，从定位效果、参数敏感性及时实性方面，对比分析 5 种基线对比算法的定位性能。

为验证所提方法的定位效果，选取 KNN、WKNN、多层感知器 (Multilayer Perceptron, MLP) 和 ELM 作为对比方法，并与所提自适应局部双 ELM 方法进行比较。其中，KNN 和 WKNN 的近邻数均设为 5，WKNN 根据指纹特征距离对近邻样本进行加权；MLP 采用两层隐藏层结构，隐藏层节点数分别为 40 和 20，训练轮数设为 100；ELM 及自适应局部双 ELM 均采用单隐层前馈网络结构，隐藏层节点数均设为 100，输入权重和隐含层偏置由随机函数初始化，隐藏层激活函数采用 Sigmoid 函数，输出权重通过 Moore-Penrose 伪逆求解。全局 ELM 的隐藏层节点数设为 100，其输入为接收机姿态方向信息与 4 个 LED 接收功率组成的 7 维联合指纹特征，用于获得测试点的初始粗略位置；局部 ELM 在自适应局部指纹库筛选后进行训练，以方向一致性校正后的 4 维接收功率特征




图10 不同定位方法的定位误差对比

作为输入，用于完成局部区域内的位置精确回归。从图10可以看出，传统KNN、WKNN方法的定位误差分布较为分散，误差分布在20~50cm之间；MLP与ELM在整体精度上有所提升，但仍存在较大的长尾误差；相比之下，自适应局部双ELM方法在中值误差、误差离散度以及均方根误差指标上均表现最优，平均定位误差可达10.52cm。

为分析指纹采样间隔与信噪比变化对定位性能的影响，对比了5种算法的定位均方根误差。如图11所示，随着指纹间隔增大，指纹库稀疏，5种方法的RMSE整体上升，定位精度下降，其中，所提方法在不同间隔下始终保持更低误差，鲁棒性最强；随着信噪比提升，各方法定位精度显著提高，并在约20dB后趋于饱和，自适应局部双ELM在全信噪比范围内均取得最佳定位性能，鲁棒性最佳。

最后，对5种方法的定位精度与定位时间进行综合比较，结果如图12所示。所提方法的RMSE最低，定位精度最优，但由于涉及局部样本筛选与局部模型更新，定位时间相对较长；全局ELM与MLP定位速度较快但精度略低；KNN和WKNN精度和实时性均不占优。综合定位精度与实时性，自适应局部双ELM表现最佳。






图12 不同定位算法的RMSE与定位时间对比

3.4 真实场景实验验证

为验证所提VLP方法在真实环境中的有效性，搭建了室内VLP硬件实验平台，如图13所示。本节真实场景实验与前述仿真实验在实验区域、指纹规模及算法参数设置上相互独立。真实场景实验区域为 $1.2\text{m} \times 1.2\text{m} \times 0.9\text{m}$ 。实验平台由发射机、接收机和数据采集端组成，发射机采用4个型号为1W的白光LED光源，安装在高度0.9m处，其坐标



(a) 不同指纹采样间隔定位均方根误差



(b) 不同信噪比定位均方根误差

图11 不同参数对5种定位算法的影响分析

分别为(0.3m, 0.3m, 0.9m)、(0.3m, 0.9m, 0.9m)、(0.9m, 0.9m, 0.9m)和(0.9m, 0.3m, 0.9m)。接收机包含型号为S6968-01的PD及前置放大电路，光信号经示波器采集并由计算机记录。在实验数据采集阶段，以 $1.2\text{m} \times 1.2\text{m}$ 的接收平面作为有效定位区域，在 x 、 y 方向分别选取10cm、30cm、50cm、70cm、90cm和110cm位置作为参考点，按照20cm的空间间隔构建 6×6 网格，共采集36个实测指纹点。为降低多光源干扰，4个LED采用时分方式依次点亮，PD在稳态下采集对应电压，形成4维指纹特征向量。每个指纹样本包含二维位置坐标、4个LED接收电压值、接收机水平旋转角和倾斜角等信息，其中PD倾斜角固定为 45° ，水平旋转角按 90° 间隔设置，分别为 0° 、 90° 、 180° 和 270° 。对应的接收面法向量分别为(0.7071, 0, 0.7071)、(0, 0.7071, 0.7071)、(-0.7071, 0, 0.7071)和(0, -0.7071, 0.7071)。程序处理中，将接收机姿态角转换为法向量，并与4维接收信号强度共同构成7维联合指纹特征。



图13 可见光室内定位实验平台

测试阶段从同一 $1.2\text{m} \times 1.2\text{m}$ 实验区域内选取25个独立测试点，测试点数据单独采集并构成独立测试集，不参与指纹库训练。与仿真实验不同，硬件实验中KNN和WKNN的近邻数设置为2，全局ELM隐藏层节点数设置为4；自适应局部双ELM的局部搜索半径设置为50cm，局部指纹样本数限制为20~30个，局部ELM隐藏层节点数设置为8，以降低实测小样本条件下的过拟合风险。

通过室内VLP实验数据构建包含位置、姿态、LED接收信号强度的实测指纹数据库，并在25个独立测试点上分别对KNN、WKNN、MLP、ELM和所提自适应局部双ELM方法进行验证。从图14中可以看出，所提方法的中位误差较小且误差

分布更集中, 整体定位性能优于 KNN、WKNN、ELM 等传统全局方法; MLP 的误差离散度较大、极值波动较为明显, 定位稳定性相对较差。与仿真实验相比, 硬件实验的测试区域较小, 测试点数量为 25 个, 且实验环境相对稳定, 因此图 14 中未出现图 10 所示的明显长尾误差。该结果表明, 在当前硬件实验条件下, 所提方法的误差分布较为集中, 但并不意味着系统不存在定位误差。综合来看, 在真实测量噪声和 PD 姿态变化共同存在的条件下, 引入自适应局部指纹库和方向一致性校正能够有效提升 VLP 的定位精度与稳定性。




图 14 不同定位算法定位误差分布

4 结 论

针对室内 VLP 系统中接收机姿态变化导致信号特征畸变、定位精度下降的问题, 提出双 ELM 定位方法。该方法先通过全局指纹库训练 ELM 实现大范围粗略定位, 再以粗略定位结果为中心构建局部指纹库, 结合接收机实时姿态校正指纹特征, 训练轻量级 ELM 实现精确定位。仿真与硬件实验表明, 所提方法平均定位误差为 10.52cm, 且 99.2% 的测试点误差控制在 46cm 内, 与 KNN、WKNN、MLP 及全局 ELM 算法相比, 在定位精度、误差稳定性上均显著更优, 且对指纹间隔、信噪比、姿态测量误差具有高鲁棒性。消融实验表明, 自适应局部指纹库构建与方向更新机制是提升定位性能的核心。所提方法提升了室内 VLP 定位精度与鲁棒性, 可为复杂室内场景下 VLP 提供了可选技术方案。

参考文献:

- [1] Wang R, Niu G, Cao Q, et al. A survey of visible light communication based indoor positioning systems[J]. *Sensors*, 2024, 24(16): 5197.
- [2] Xue J, Zhang J, Gao Z, et al. Enhanced WiFi CSI fingerprints for device-free localization with deep learning representations[J]. *IEEE Sensors Journal*, 2022, 23(3): 2750—2759.
- [3] Wu C, Wong I C, Wang Y, et al. Experimental study of blue-tooth indoor positioning using rss and deep learning algorithms[J]. *Mathematics*, 2024, 12(9): 1386.
- [4] Gomes E L, Fonseca M S P, Lazzaretti A E, et al. Sliding window, hierarchical classification, regression, and genetic algorithm for RFID indoor positioning systems[J]. *Expert Systems with Applications*, 2024, 238: 122298.
- [5] Mäkelä M, Olkkonen M K, Kirkko-Jaakkola M, et al. Ubiquitous UWB ranging error mitigation with application to infrastructure-free cooperative positioning[J]. *IEEE Journal of Indoor and Seamless Positioning and Navigation*, 2024, 2: 143—150.
- [6] 张雁鹏, 张容容, 张宏雁, 等. 基于扩展状态观测器的可见光成像通信列车定位光源自适应获取方法[J]. *光学学报*, 2025, 45(11): 1111001.
- [7] Zhang Yanpeng, Zhang Rongrong, Zhang Hongyan, et al. Adaptive light source acquisition method for train positioning based on extended state observer in visible light imaging communication[J]. *Acta Optica Sinica*, 2025, 45(11): 1111001.
- [8] Rekka V P, Iliadis L A, Sotiroudis S P, et al. Artificial intelligence in visible light positioning for indoor IoT: A methodological review[J]. *IEEE Open Journal of the Communications Society*, 2023, 4: 2838—2869.
- [9] 王创世, 陈勇, 刘焕淋, 等. 基于注意力机制的可见光定位单元模型复制[J]. *中国激光*, 2024, 51(8): 0806002.
- [10] Wang Chuangshi, Chen Yong, Liu Huanlin, et al. Model replication of visible light positioning units based on attention mechanism[J]. *Chinese Journal of Lasers*, 2024, 51(8): 0806002.
- [11] 许浩, 王旭东, 吴楠. 基于卷积神经网络的室内可见光指纹定位方法[J]. *激光与光电子学进展*, 2021, 58(17): 1706008.
- [12] Xu Hao, Wang Xudong, Wu Nan. Indoor visible light fingerprint positioning scheme based on convolution neural network[J]. *Laser & Optoelectronics Progress*, 2021, 58(17): 1706008.
- [13] 于建勇, 胡晓莉, 王倩, 等. 基于指纹修正与网络融合算法的可见光定位系统应用[J]. *光学学报*, 2025, 45(16): 1606005.
- [14] Yu Jianyong, Hu Xiaoli, Wang Qian, et al. Application of visible light positioning system based on fingerprint correction and network fusion algorithms[J]. *Acta Optica Sinica*, 2025, 45(16): 1606005.
- [15] 马玉磊, 张兵. 基于深度学习的可见光通信系统室内三维定位[J]. *光学技术*, 2024, 50(2): 201.
- [16] Ma Yulei, Zhang Bing. Deep learning based indoors dimensional positioning for visible light communication system[J]. *Optical Technology*, 2024, 50(2): 201.
- [17] 许一祎, 冯莉芳, 薛卓. 基于矩阵分解与深度神经网络的室内定位方法[J]. *光学学报*, 2025, 45(10): 1010001.
- [18] Xu Yiyi, Feng Lifang, Xue Zhuo. Indoor positioning system based on matrix factorization and deep neural networks[J]. *Acta Optica Sinica*, 2025, 45(10): 1010001.
- [19] 杜聪, 邵建华, 杨薇, 等. 网络搜索法优化的支持向量机室内可见光定位[J]. *激光杂志*, 2021, 42(3): 104—109.
- [20] Du Cong, Shao Jianhua, Yang Wei, et al. Indoor visible light positioning based on support vector machine optimized by grid search[J]. *Laser Journal*, 2021, 42(3): 104—109.
- [21] 贾科军, 牛振, 于凯, 等. 基于 SSA-ELM 神经网络的室内可见光定位系统[J]. *光通信研究*, 2025, 51(1): 230154.
- [22] Jia Kejun, Niu Zhen, Yu Kai, et al. Indoor visible light positioning system based on SSA-ELM neural network[J]. *Optical Communication Research*, 2025, 51(1): 230154.
- [23] 曹海峰, 王晓亮. 基于深度学习与 RSS 滤波的可见光室内定位算法[J]. *光学技术*, 2024, 50(3): 361.
- [24] Cao Haifeng, Wang Xiaoliang. Indoor visible light positioning algorithm based on deep learning and RSS filtering[J]. *Optical Technology*, 2024, 50(3): 361.
- [25] Liu R, Liang Z, Li W. Fingerprint-based visible light positioning using adaptive WKNN algorithm with reliable reference nodes[J]. *IEEE Transactions on Instrumentation and Measurement*, 2025, 74: 5506609.
- [26] Deng L, Fan Y, Zhao Q. Indoor visible light tilt-resilient positioning based on RSS fingerprint self-transferability[J]. *IEEE Photonics Technology Letters*, 2025, 37(12): 679—682.