引用格式：姜浩, 郭子坚, 孙瑾. 基于 CSI 的单 AP 港口人员指纹定位方法 [J]. 电子科技大学学报, 2026, 55(3): 398-410.
JIANG H, GUO Z J, SUN J. Single AP port personnel fingerprint location method based on CSI[J]. Journal of University of Electronic Science and Technology of China, 2026, 55(3): 398-410.

基于 CSI 的单 AP 港口人员指纹定位方法

姜 浩*，郭子坚，孙 瑾

（大连理工大学海岸与海洋工程全国重点实验室，大连 116024）

摘要：港口是我国重要的物流和交通枢纽，高精度的港口人员定位系统在安全生产和管理过程中发挥着重要作用。该文将径向基函数（RBF）和极限学习机（ELM）结合，提出了一种基于信道状态信息（CSI）的 RBF-ELM 港口人员定位方法，实现单个接入点（AP）进行人员定位。在离线训练阶段，首先将定位区域网格化，并测量各网格位置的 CSI 数据；将幅值差和线性重构的相位信息融合构造位置指纹，并使用主成分分析（PCA）进行降维处理。最后，将模拟退火（SA）嵌入量子粒子群优化（QPSO）算法中，提高全局搜索能力，寻找模型最优参数，进而提升定位模型的精度和泛化能力。在在线预测阶段，通过 WKNN 匹配算法将模型的预测结果与位置库中的标签和坐标进行匹配，以获得更为精确的定位坐标。同时，采用动态遗忘因子的权值更新方式，只需采集部分校准数据即可完成对定位模型权值的更新，有效缓解随时间和环境变化引起的定位精度衰退问题。在模拟港口的场景下进行实验验证，该定位系统在视距（LOS）环境下达到 1 m 定位精度的概率在 92% 以上，静态平均误差为 0.58 m，动态平均误差为 0.86 m；在非视距（NLOS）环境下也可获得 0.67 m 的静态平均定位误差。所提算法相比其他定位方法在定位精度、时效性和稳定性上均有所提升。

关键词：港口人员定位；信道状态信息；极限学习机；量子粒子群；动态权值更新
中图分类号：U65; TP391.4 **文献标志码：**A DOI: 10.12178/1001-0548.2025032

Single AP port personnel fingerprint location method based on CSI

JIANG Hao*, GUO Zijian, and SUN Jin

(State Key Laboratory of Coastal and Offshore Engineering, Dalian University of Technology, Dalian 116024, China)

Abstract: The port is an important logistics and transportation hub in our country, the high-precision port personnel positioning system plays an important role in the process of safety production and management. By combining radial basis function (RBF) and extreme learning machine (ELM), an RBF-ELM port personnel location method based on channel state information (CSI) is proposed to realize personnel location by a single access point (AP). In the offline training stage, the positioning area is first gridded and the CSI data of each grid position is measured; position fingerprints are constructed by fusing the amplitude difference and linearly reconstructed phase information, and dimensionality reduction was performed by principal component analysis (PCA); subsequently, simulated annealing (SA) is embedded into quantum particle swarm optimization (QPSO) to improve the global search ability, find the optimal parameters of the model, and thereby improve the accuracy and generalization ability of positioning model. In the online prediction stage, the prediction results of the model are matched with labels and coordinates in the location library by weighted K-nearest neighbors (WKNN) matching algorithm to obtain more accurate positioning coordinates. At the same time, the weight update method of dynamic forgetting factor is adopted, and only part of calibration data can be collected to complete the update of positioning model weight, which effectively alleviates the problem of positioning accuracy decline caused by changes in time and environment. In the simulated port scenario, the probability of the positioning accuracy of the system reaching 1m in line-of-sight (LOS) environment is more than 92%, the static average error is 0.58 m, and the dynamic average error is 0.86 m. The static average positioning error of 0.67 m can also be obtained in non-line-of-sight (NLOS) environment. Compared with other positioning methods, the proposed algorithm has improved positioning accuracy, timeliness and stability.

收稿日期：2025−02−12
基金项目：国家自然科学基金（52272318）
作者简介：姜浩，博士生，主要从事机器人巡检和港口交通运输方面的研究。
*通信作者 E-mail: jianghao@mail.dlut.edu.cn

Key words: port personnel location; channel state information; extreme learning machine; quantum particle swarm; dynamic weight update

港口是我国重要的物流和交通枢纽，关系到国民经济的发展和国家贸易安全。为保障港口作业的安全和高效，人员定位成为关键的技术手段[1]。目前，港口人员定位方法主要分为基于测距和非测距两类，许多研究者对此进行了深入研究，取得了显著成果。

基于 Wi-Fi 的定位技术主要分为测距和指纹两类。测距方法利用接收信号强度值（received signal strength indication, RSSI）计算目标与多个接入点（access point, AP）基站之间的距离，从而推算目标的坐标。然而，港口环境复杂，存在多路径传播和非视距（non line of sight, NLOS）时延，这导致测距法的定位精度一般在 5～8 m 左右。为了解决这一问题，研究者们提出了多种改进的方法，如基于改进卡尔曼滤波的定位方案，有效抑制了 NLOS 时延的影响。文献 [2] 提出基于北斗高精度定位的智慧港口创新应用，积极提升港口运营能力，以应对不断增加的货运吞吐量需求。文献 [3] 提出基于 5G+的人员定位系统在港口安全管理中的应用，较好地为港口安全生产管理提供技术支持。文献 [4] 通过分析组合导航系统中传感器的状态变化对定位精度的影响，设计了一种基于传感器工作状态的模糊逻辑推理系统。而指纹定位法通过在特定位置采集的信号特征来表示位置信息，省去了距离和角度测量的需要[5]。然而，港口环境下的 Wi-Fi 指纹定位依然面临一些挑战：指纹样本的噪声干扰、指纹库的构建与维护复杂、接入点稀疏分布、指纹匹配的精度和效率等问题依然突出。为应对这些挑战，一些研究者提出了自适应核主成分分析算法，以减少定位过程中的资源消耗。

尽管测距和指纹定位都依赖于 RSSI 进行位置估计，但由于 RSSI 信号是多径传播的叠加效果，具有粗粒度特性，基于 RSSI 的定位方法难以实现高精度定位。因此，研究者们逐渐关注信道状态信息（channel state information, CSI），该参数可更精准地刻画无线信号的多径传播特征。研究表明，基于 CSI 的定位技术在室内环境中已取得了一定成果，但对港口人员定位的研究相对较少[6]。

为了提高定位系统的鲁棒性，选择融合 CSI 幅值差和相位信息，采用滑动平均、线性重构和主成分分析等方法进行数据压缩和特征提取。为实现快速且精准的定位，构建了结合径向基函数（radial basis function, RBF）和极限学习机（extreme learning machine, ELM）的 RBF-ELM 模型。为了提高模型的泛化能力，通过对量子粒子群优化（quantum particle swarm optimization, QPSO）算法进行改进，嵌入模拟退火算法（simulated annealing, SA）以寻找最优参数。在离线阶段，采用 WKNN（weighted K-nearest neighbors）匹配算法对模型输出进行精准定位。为增强模型的长期稳定性，引入动态遗忘因子，以便在定位环境变化时仅需少量校准数据即可完成模型的更新，而无需重新训练模型。

1　相关理论

1.1　信道状态信息

信号传输模型如下[7]：

$$\boldsymbol{Y} = \boldsymbol{M}\boldsymbol{X} + \boldsymbol{a} \tag{1}$$

式中，$\boldsymbol{M}$是信道频率响应（channel frequency response, CFR）矩阵；$\boldsymbol{a}$为加性高斯白噪声，$\boldsymbol{X}$和$\boldsymbol{Y}$分别表示发送和接收的信号矢量。

$$\boldsymbol{M} = [\mathrm{CSI}_1, \mathrm{CSI}_2, \cdots, \mathrm{CSI}_k, \cdots, \mathrm{CSI}_b]^{\mathrm{T}} \tag{2}$$

式中，b表示正交频分复用（orthogonal frequency division multiplexing, OFDM）系统中用于传输信号的子载波个数；CSI_k表示第k个子载波的频率响应：

$$\mathrm{CSI}_k = |\mathrm{CSI}_k| \mathrm{e}^{\mathrm{j}\theta_k} \tag{3}$$

式中，$|\mathrm{CSI}_k|$和θ_k分别代表第k个子载波的幅度和相位。在多输入多输出（multiple-input and multiple-output, MIMO）系统中，所有天线对形成的信道状态信息矩阵为：

$$\boldsymbol{H} = \begin{bmatrix} H_{11} & H_{12} & \cdots & H_{1t} \\ H_{21} & H_{22} & \cdots & H_{2t} \\ \cdots & \cdots & \cdots & \cdots \\ H_{r1} & H_{r2} & \cdots & H_{rt} \end{bmatrix} \tag{4}$$

式中，H_{rt}表示发射和接收天线之间通信链路的信道状态信息矩阵。复数矩阵$\boldsymbol{H}$的总维度为$t \times r \times s$，t、r和s分别为发射天线数、接收天线数及子载波数。采用 1 个发射天线和 3 个接收天线进行实验，子载波个数为 30 个。

在无线通信系统中，信道频率响应矩阵$\boldsymbol{M}$与信道状态信息矩阵$\boldsymbol{H}$之间的关系可以通过以下方式建立联系。

信道频率响应矩阵通常表示在不同频率下的信道响应，它是一个描述信道在不同频率上增益和相位变化的矩阵。CFR 矩阵的元素可以用来描述从发射天线到接收天线之间每个频率点的信道特性。而信道状态信息矩阵则是指在给定时刻或频率上，信道的增益和衰减信息。它包含了关于信道的时域和频域的信息，通常是通过测量或者估计得到的。

假设一个多天线系统，其中发射端有N_t个天线，接收端有N_r个天线，信道矩阵$\boldsymbol{H}$描述了从发射天线到接收天线的时域信道状态信息。它的尺寸是$N_t \times N_r$，每个元素H_{ij}表示从第j个发射天线到第i个接收天线的信道响应。在频域中，信道频率响应矩阵$\boldsymbol{M}$则描述了不同频率点下的信道响应。假设信道的频率响应矩阵是一个$N_t \times N_r$的矩阵，每个元素表示不同频率下的信道增益。信道的频率响应矩阵$\boldsymbol{M}$和时域信道矩阵$\boldsymbol{H}$之间可以通过傅里叶变换来建立联系：

$$\boldsymbol{M}(\omega) = \Gamma\{\boldsymbol{H}(t)\} \tag{5}$$

式中，Γ表示傅里叶变换操作。设$\boldsymbol{H}(t)$是时域信道状态信息矩阵，它的元素$h_{i,j}(t)$表示从发射天线j到接收天线i的时域信道响应。在频域上，信道频率响应矩阵$\boldsymbol{M}(\omega)$的元素$m_{i,j}(\omega)$表示对应频率下的信道响应：

$$m_{i,j}(\omega) = \int_{-\infty}^{\infty} h_{i,j}(t) \mathrm{e}^{-\mathrm{j}\omega t} \mathrm{d}t \tag{6}$$

这样，本文通过傅里叶变换将时域的信道状态信息矩阵$\boldsymbol{H}$转换为频域的信道频率响应矩阵$\boldsymbol{M}$。

为验证 CSI 定位性能，在模拟港口的实验环境下随机选择 4 个参考点，分别使用 1 个发射天线和 3 个接收天线进行实验，在每个参考点间隔 10 min 采集 3 次数据，采样时间 10 s，采样频率为 100 Hz。图 1 展示了 4 个参考点采集一次的幅值，可以看出仅使用 1 个 AP 就可获得满足定位需求的信息；不同参考点在同一根天线上存在特征差异，不同位置的 CSI 可用于定位。图 2 为同一个参考点上不同时间点采集到的数据，可以看到 3 次采集数据特征相似，表明了 CSI 信号的稳定性。

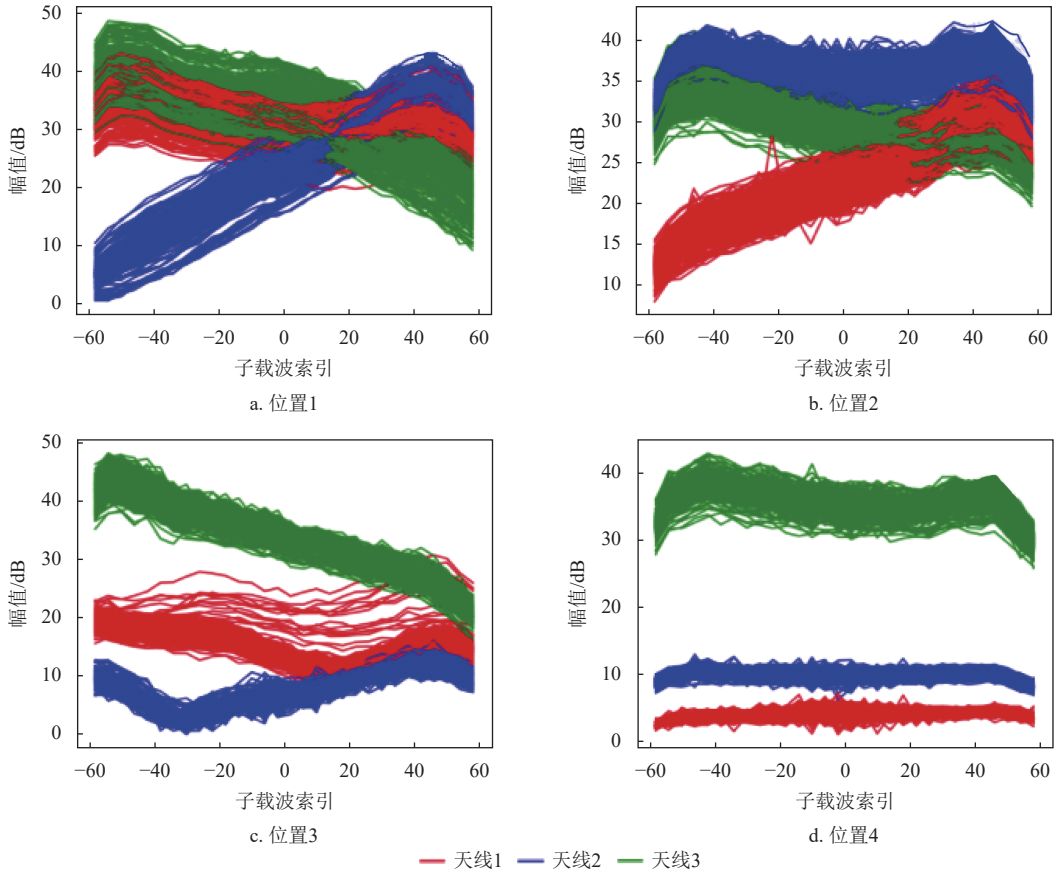


图 1　不同参考点 CSI 幅值图

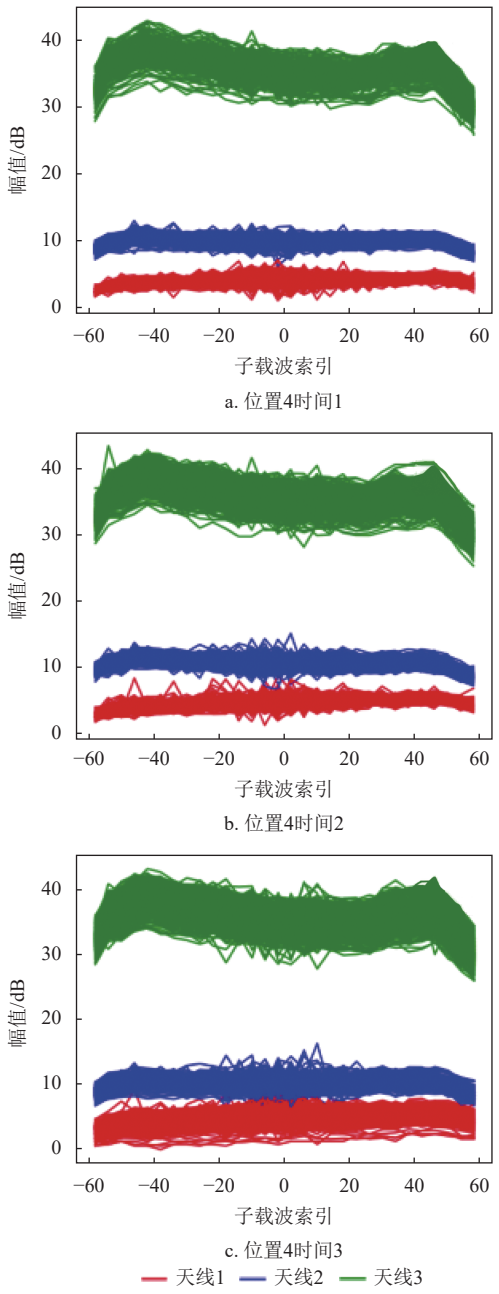


图 2　不同时间点的 CSI 幅值图

1.2　幅值差信息

针对 CSI 定位场景，现有研究多利用幅值信息完成指纹构建。为进一步提升指纹的抗干扰能力，本文将相邻子载波的幅度差值作为定位指纹，计算如下：

$$\mathrm{AD}_{i,j}=\begin{cases}A_{i,j+1}-A_{i,j} & i=1,2,3;j=1,2,\cdots,29\\ A_{i,1}-A_{i,j} & i=1,2,3;j=30\end{cases} \tag{7}$$

式中，$A_{i,j}=\left|H_{i,j}\right|$表示第$i$个天线上第$j$个子载波的幅值。

1.3　相位信息线性重构

由于采集到的相位信息受设备中心频率偏差和采样频率偏差影响，无法直接用于定位指纹的构建，所以需要对相位信息进行线性重构[8]。即：

$$\varphi_i=\alpha\theta_i+\nu \tag{8}$$

式中，α代表受设备中心频率偏差影响的系数，决定了相位的缩放；ν代表受采样频率偏差影响的偏移量，决定了相位的平移。实现初步的相位补偿和干扰消除后，相位线性变换可以表示为：

$$\hat{\varphi}_i=\varphi_i-2\pi\frac{k_i}{c}\Delta t+\beta+Z \tag{9}$$

式中，$\hat{\varphi}_i$和φ_i表示第i个子载波的测量值和真实值；Δt表示接收机与发射机之间的时间差；β为收发端载波频率不同导致的相位偏移量；Z为测量噪声；k_i为第i个子载波对应的索引号，不同带宽下索引号也不同；c表示快速傅里叶变换的大小。使用线性变换对相位信息做进一步的处理获取真实相位，线性变换方程的斜率和截距分别为d和e，变换如下[9]：

$$d=\frac{\hat{\varphi}_n-\hat{\varphi}_1}{k_n-k_1}=\frac{\varphi_n-\varphi_1}{k_n-k_1}-\frac{2\pi}{c}\delta \tag{10}$$

$$e=\frac{1}{n}\sum_{j=1}^{n}\hat{\varphi}_j=\frac{1}{n}\sum_{j=1}^{n}\varphi_j-\frac{2\pi\delta}{nc}\sum_{j=1}^{n}k_j+\beta \tag{11}$$

式中，n表示子载波数量；$\sum_{j=1}^{n}k_j=0$；$e=\frac{1}{n}\sum_{j=1}^{n}\varphi_j+\beta$。通过测量相位$\hat{\varphi}_i$减去线性项$dk_i+e$，可以获得真实相位的线性组合，表示如下：

$$\hat{\varphi}_i=\varphi_i-dk_i-e=\varphi_i-\frac{\varphi_n-\varphi_1}{k_n-k_1}k_i-\frac{1}{n}\sum_{j=1}^{n}\varphi_j \tag{12}$$

幅值差和相位差作为无线信号的关键特征，能够反映港口环境中的人员位置变化。通过将这些信号特征输入 RBF-ELM 模型，能够利用该模型强大的非线性映射能力，提取出更加精确的位置信息。同时，SAQPSO 算法则通过优化 RBF-ELM 的超参数，进一步提高定位精度。通过这样的结合，不仅可以有效捕捉信号中的空间信息，还能够提升算法的鲁棒性和全局搜索能力，进而为精准定位提供理论支持。接下来，本文将详细探讨如何将幅值差与相位差信息与 RBF-ELM 及 SAQPSO 方法结合，以实现高效的港口人员定位。

2　定位模型

2.1　RBF-ELM 模型

ELM 是一种基于单隐藏层前馈神经网络（single-

hidden layer feedforward neutral network, SLFN）改良的机器学习模型，其计算过程是随机化产生输入层到隐含层的权重和偏置，通过分析计算得到隐含层到输出层的权重，并且权值可根据新数据动态调整[10]，适用于实时定位。

将径向基函数 RBF 加入 ELM 神经网络算法中，其结构如图 3 所示。RBF-ELM 同时具备 RBF 的全局逼近能力和 ELM 学习速度快、算法简单的优势，拥有更好的泛化能力。

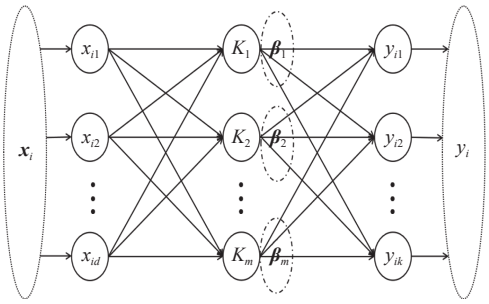


图 3 RBF-ELM 模型结构

图 3 中，$K_1, K_2, \cdots, K_m$是径向基函数，选择高斯核函数作为径向基函数的具体表示形式：

$$K(\boldsymbol{x}, \boldsymbol{\mu}_i, \sigma_i) = \exp(-\|\boldsymbol{x}-\boldsymbol{\mu}_i\|^2/2\sigma_i^2) \tag{13}$$

式中，$\boldsymbol{x}$为输入的特征量；$\boldsymbol{\mu}_i = (\mu_{i1}, \mu_{i2}, \cdots, \mu_{id})^{\mathrm{T}}$为第$i$个核函数中心；$\sigma_i$为第$i$个核函数的扩展参数宽度。为避免径向基函数导致过于集中或分散，扩展参数宽度计算如下：

$$\sigma_i = \frac{f_{\max}}{\sqrt{2m}} \tag{14}$$

式中，$f_{\max}$为所选取中心之间的最大距离；m是隐层节点的个数。

$\boldsymbol{\beta}_i = (\beta_{i1}, \beta_{i2}, \cdots, \beta_{ik})^{\mathrm{T}}$是连接第$i$个核和$k$个输出神经元的权重向量。对于输入为$\boldsymbol{x} \in R^d$并具有$m$个核的网络输出为：

$$f(\boldsymbol{x}) = \sum_{i=1}^{m} \boldsymbol{\beta}_i K_i(\boldsymbol{x}) \tag{15}$$

样本集$D = \{(\boldsymbol{x}_j, \boldsymbol{y}_j)\}$，$\boldsymbol{x}_j \in R^d$，$\boldsymbol{y}_j \in R^k$，$j = 1, 2, 3, \cdots n$，存在合适的$\boldsymbol{\mu}_i$、$\sigma_i$、$\boldsymbol{\beta}_i$使得式 (15) 变为：

$$\sum_{i=1}^{m} \boldsymbol{\beta}_i \exp\left(-\left\|\boldsymbol{x}_j - \boldsymbol{\mu}_i\right\|^2/2\sigma_i^2\right) = \boldsymbol{y}_j \tag{16}$$

上式可缩写为：

$$\boldsymbol{G\beta} = \boldsymbol{Y} \tag{17}$$

式中，$\boldsymbol{G} = \begin{bmatrix} K(\boldsymbol{x}_1, \boldsymbol{\mu}_1, \delta_1) & \cdots & K(\boldsymbol{x}_1, \boldsymbol{\mu}_m, \delta_m) \\ \vdots & \cdots & \vdots \\ K(\boldsymbol{x}_n, \boldsymbol{\mu}_1, \delta_1) & \cdots & K(\boldsymbol{x}_n, \boldsymbol{\mu}_m, \delta_m) \end{bmatrix}$；$\boldsymbol{\beta} = \left(\boldsymbol{\beta}_1^{\mathrm{T}}, \boldsymbol{\beta}_2^{\mathrm{T}}, \cdots, \boldsymbol{\beta}_m^{\mathrm{T}}\right)^{\mathrm{T}}$；$\boldsymbol{Y} = (\boldsymbol{y}_1^{\mathrm{T}}, \boldsymbol{y}_2^{\mathrm{T}}, \cdots, \boldsymbol{y}_n^{\mathrm{T}})^{\mathrm{T}}$。

采用最小二乘法求解下式从而获得$\boldsymbol{\beta}$的最优解：

$$\min_{\boldsymbol{\beta}} \|\boldsymbol{G\beta} - \boldsymbol{Y}\| \tag{18}$$

其最小范数的最小二乘解$\hat{\boldsymbol{\beta}}$为：

$$\hat{\boldsymbol{\beta}} = \boldsymbol{G}^{\dagger}\boldsymbol{Y} \tag{19}$$

式中，$\boldsymbol{G}^{\dagger}$为矩阵 $\boldsymbol{H}$ 的增广逆，简称伪逆。通常以正交法计算：

$$\boldsymbol{G}^{\dagger} = \begin{cases} (\boldsymbol{G}^{\mathrm{T}}\boldsymbol{G})^{-1}\boldsymbol{G}^{\mathrm{T}} & \boldsymbol{G}^{\mathrm{T}}\boldsymbol{G}\text{可逆} \\ \boldsymbol{G}^{\mathrm{T}}(\boldsymbol{G}\boldsymbol{G}^{\mathrm{T}})^{-1} & \boldsymbol{G}\boldsymbol{G}^{\mathrm{T}}\text{可逆} \end{cases} \tag{20}$$

在 RBF-ELM 方法中，输入层到隐藏层之间的参数（即 PRBF 核的中心）通过随机方式获得，然而这些中心以及核宽度的选取会严重影响网络的泛化能力，故需要对 RBF 核的参数进一步地研究调整，选择使用改进的 QPSO 算法来寻求合适参数。

2.2 SAQPSO

QPSO 算法中每个粒子以一定概率出现在解空间的任意位置，每个粒子拥有更大的搜索范围使得算法有更优的全局搜索能力[11]。

粒子i的位置向量为$\boldsymbol{X}_i$，通过P_i可得粒子i的历史最优位置，P_g可得全局的最优位置。向量$\boldsymbol{P} = (P_1, P_2, \cdots, P_d)$指每个粒子的局部吸引点，由下式获得：

$$P_d = \varphi P_{i,d} + (1-\varphi)P_{g,d} \tag{21}$$

式中，φ表示 0～1 间均匀分布的随机数。

QPSO 算法由薛定谔方程求得粒子在空间中某一位置出现的概率密度，再用蒙特卡罗模拟法确定粒子的位置，具体如下：

$$x_{i,d}(t) = p \pm \frac{L}{2}\mathrm{In}(1/\mu) \tag{22}$$

式中，μ是 [0,1] 的随机数，当μ大于 0.5 时式中取‘+’，否则取‘−’，L定义如下：

$$L(t+1) = 2z|m\mathrm{best} - x_{i,d}(t)|$$
$$m\mathrm{best} = \frac{1}{N}\sum_{i=1}^{N} P_i = \left(\frac{1}{N}\sum_{i=1}^{N} P_{i,1}, \frac{1}{N}\sum_{i=1}^{N} P_{i,2}, \cdots, \frac{1}{N}\sum_{i=1}^{N} P_{i,d}\right) \tag{23}$$

式中，N为粒子数目；z是收缩−扩张因子；t为当前迭代次数，则粒子位置的更新方程为：

$$x_{i,d}(t+1)=p\pm z|m\text{best}-x_{i,d}(t)|\ln(1/\mu) \tag{24}$$

式中，z是算法中唯一需要设定的参数，其计算公式为：

$$z=\frac{(1-0.5)T}{T}+0.5 \tag{25}$$

式中，T为最大迭代次数。当z较大时收敛速度较快；较小时收敛速度较慢。

式 (21) 通过φ选择了随机数，体现出个体和种群信息融合的优点，但其在粒子局部搜索方面针对性不够。因此将参数φ最大取值由 1 变为α，当α大于 0.5 时φ为$[0.5,\alpha]$的随机数，否则为$[0,\alpha]$的随机数。

$$\alpha=(0.9-0.3)(T-t)/T+0.3 \tag{26}$$

QPSO 提升了粒子的全局搜索能力，但当某一粒子到达局部最优时会使其他粒子向该粒子聚集，使算法陷入局部最优[12]，将模拟退火算法 SA 嵌入 QPSO 算法构造 SAQPSO，以一定概率接受差解的思想寻找全局最优，避免早熟现象。SA 算法根据 Metropolis 准则进行计算，以概率 1 接受更优解，以某种概率接受差解，可以有效地跳出局部最优，公式如下：

$$p=\begin{cases}1 & E(i)\leqslant E(j)\\ \mathrm{e}^{-\left(\frac{E(j)-E(i)}{\mathrm{K}T}\right)}=\mathrm{e}^{-\frac{\Delta E}{\mathrm{K}T}} & \text{others}\end{cases} \tag{27}$$

式中，$E(i)$、$E(j)$分别为i、j下的内能，表示粒子适应度；$\Delta E=E(f)-E(i)$表示内能增量；T为温度；K为玻尔兹曼常数。在粒子运动过程中，如果粒子的当前位置优于此粒子的历史最优时，将当前位置更新为粒子的历史最优，否则根据 Metropolis 准则来计算将当前位置更新为粒子历史最优位置的概率，全局最优更新也选取这种方式，为防止最优位置的丢失会单独设一个空间进行保存但不参与任何粒子更新。

2.3　动态遗忘因子权值更新

引入遗忘因子的在线顺序学习方法，使得初始定位模型能够根据在线阶段获得的校准数据进行更新，不需要重新训练模型[13]。

在在线顺序学习方法中，遗忘因子的选择直接影响模型对新数据的适应能力和历史数据的影响程度。通常，遗忘因子的范围在 0～1。值较大的遗忘因子意味着模型更关注新数据，较小的遗忘因子则表示模型对历史数据的记忆较多。对于长期的港口定位精度来说，更适合使用一个适中的值（0.45～0.60），随着时间推移，根据实际的电磁环境变化情况逐步动态调整。即通过计算模型在每一时刻的定位精度来动态调节遗忘因子的值。若定位精度提升，遗忘因子可以适当减小，以保留更多的历史信息；若精度下降，则可以增大遗忘因子，减少历史数据的影响，使得模型更快速地适应新的数据。

在线顺序学习阶段，当有新的校准数据到达时，根据以下优化对象来对模型更新：

$$\min_{\boldsymbol{\beta}}\left\|\begin{bmatrix}\boldsymbol{H}_0\\ \boldsymbol{H}_1\end{bmatrix}\boldsymbol{\beta}-\begin{bmatrix}\boldsymbol{Y}_0\\ \boldsymbol{Y}_1\end{bmatrix}\right\| \tag{28}$$

加入遗忘因子后优化对象变为：

$$\min_{\boldsymbol{\beta}}\left\|\begin{bmatrix}\lambda\boldsymbol{H}_0\\ \boldsymbol{H}_1\end{bmatrix}\boldsymbol{\beta}-\begin{bmatrix}\lambda\boldsymbol{Y}_0\\ \boldsymbol{Y}_1\end{bmatrix}\right\| \tag{29}$$

式中，$\lambda\in[0,1]$为遗忘因子，$\lambda=1$时表示新数据与过去数据一样重要，$\lambda<1$表示过去数据重要性低于新数据。依据式 (29) 可以推断出：

$$\boldsymbol{\beta}^{(1)}=\boldsymbol{G}_1^{-1}\begin{bmatrix}\lambda\boldsymbol{H}_0\\ \boldsymbol{H}_1\end{bmatrix}^{\mathrm{T}}\begin{bmatrix}\lambda\boldsymbol{Y}_0\\ \boldsymbol{Y}_1\end{bmatrix} \tag{30}$$

式中，$\boldsymbol{G}_1=\begin{bmatrix}\lambda\boldsymbol{H}_0\\ \boldsymbol{H}_1\end{bmatrix}^{\mathrm{T}}\begin{bmatrix}\lambda\boldsymbol{H}_0\\ \boldsymbol{H}_1\end{bmatrix}$也可以表示为：

$$\boldsymbol{G}_1=\begin{bmatrix}\lambda\boldsymbol{H}_0 & \boldsymbol{H}_1\end{bmatrix}\begin{bmatrix}\lambda\boldsymbol{H}_0\\ \boldsymbol{H}_1\end{bmatrix}=\lambda^2\boldsymbol{G}_0+\boldsymbol{H}_1^{\mathrm{T}}\boldsymbol{H}_1 \tag{31}$$

式中，$\boldsymbol{G}_0=\boldsymbol{H}_0^{\mathrm{T}}\boldsymbol{H}_0$并且：

$$\begin{aligned}&\begin{bmatrix}\lambda\boldsymbol{H}_0\\ \boldsymbol{H}_1\end{bmatrix}^{\mathrm{T}}\begin{bmatrix}\lambda\boldsymbol{Y}_0\\ \boldsymbol{Y}_1\end{bmatrix}=\lambda^2\boldsymbol{H}_0^{\mathrm{T}}\boldsymbol{Y}_0+\boldsymbol{H}_1^{\mathrm{T}}\boldsymbol{Y}_1=\\ &\lambda^2\boldsymbol{G}_0\boldsymbol{G}_0^{-1}\boldsymbol{H}_0^{\mathrm{T}}\boldsymbol{Y}_0+\boldsymbol{H}_1^{\mathrm{T}}\boldsymbol{Y}_1=\\ &\lambda^2\boldsymbol{G}_0\boldsymbol{\beta}^{(0)}+\boldsymbol{H}_1^{\mathrm{T}}\boldsymbol{Y}_1=\\ &\boldsymbol{G}_1\boldsymbol{\beta}^{(0)}-\boldsymbol{H}_1^{\mathrm{T}}\boldsymbol{H}_1\boldsymbol{\beta}^{(0)}+\boldsymbol{H}_1^{\mathrm{T}}\boldsymbol{Y}_1\end{aligned} \tag{32}$$

综上可得：

$$\boldsymbol{\beta}^{(1)}=\boldsymbol{\beta}^{(0)}+\boldsymbol{G}_1^{-1}\boldsymbol{H}_1^{\mathrm{T}}\left(\boldsymbol{Y}_1-\boldsymbol{H}_1\boldsymbol{\beta}^{(0)}\right) \tag{33}$$

当 k+1 组数据输入模型后，新的输出权值为：

$$\begin{aligned}&\boldsymbol{\beta}^{(k+1)}=\boldsymbol{\beta}^{(k)}+\boldsymbol{G}_{k+1}^{-1}\boldsymbol{H}_{k+1}^{\mathrm{T}}\left(\boldsymbol{Y}_{k+1}-\boldsymbol{H}_{k+1}\boldsymbol{\beta}^{(k)}\right)\\ &\boldsymbol{G}_{k+1}=\lambda^2\boldsymbol{G}_k+\boldsymbol{H}_{k+1}^{\mathrm{T}}\boldsymbol{H}_{k+1}\end{aligned} \tag{34}$$

权值因子依照如下公式迭代：

$$\lambda=\lambda-\frac{1}{5\pi}\arctan(E) \tag{35}$$

式中，E为模型精度在每次更新前后的变化程度，选择平滑性好的 arctan 作为激活函数，适合港口连续且相对稳定的环境变化。当 arctan 的缩放系数为

1/(5π)时能够使遗忘因子的变化更加稳定[14]。

3 定位系统实现

3.1 定位系统框架

基于 CSI 的定位方法分为两部分：离线训练和在线预测阶段。定位系统框架如图 4 所示。

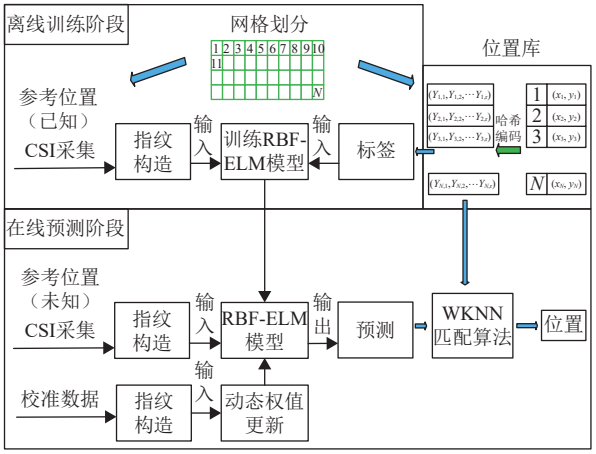


图 4 定位框架结构图

在基于 CSI 的单 AP 人员指纹定位方法中，通过校准指纹信息就可以进行权值更新，具体更新方法如下。

1）特征提取与聚类优化。通过 Kmeans 算法对同一位置的多个 CSI 向量进行聚类，选取代表性特征作为指纹，这种方法可减少测量误差对权值的影响，提升定位精度。

2）在线增量学习。利用 XGBoost 机器学习模型，将校准指纹作为输入特征，真实位置作为标签，通过增量训练逐步优化模型参数。新数据到达时，仅需更新模型的部分参数，从而有效降低了计算开销。

3）动态匹配策略。结合在线阶段采集的 CSI 数据，采用主成分分析降维，动态调整近邻权重或特征空间分布，实现权值自适应更新，但需确保 AP 硬件配置固定、环境干扰可控，且校准指纹覆盖目标区域的空间分布，若环境发生显著变化（如新增障碍物），需重新采集校准数据更新指纹库。

在较小的网格划分（如 1.0 m×1.0 m）下，精度较高，但随着网格大小增大，定位精度会逐步下降，因为更大的网格可能会将多个位置划分到同一网格内，导致定位精度下降。但网格划分越小，定位精度越高，且计算开销也越大。

通过实验分别在不同的网格大小下（0.5 m×0.5 m, 1.0 m×1.0 m, 1.5 m×1.5 m）进行训练和测试，评估定位精度，以量化网格划分对精度的影响，测试结果如表 1 所示。通过多次实验得出，1.0 m×1.0 m 的网格划分提供了较高的定位精度。由于该划分的网格较小，能够较为准确地捕捉到电磁环境中细微的空间变化，确保模型能够区分相邻位置的特征差异，从而提高定位系统的分辨率和精度。综上，在离线训练阶段，先将定位场景进行虚拟网格划分，网格划分大小为 1.0 m×1.0 m，对每个划分的网格进行编号，将网格的中心位置作为该网格对应的坐标。在每个参考位置采集数据，采用下文将介绍到的指纹构造方法，对 CSI 信息进行处理生成模型的输入，使用 one-hot 编码对网格编码作为标签，但由于定位范围内网格数众多使得标签维度过大，且指纹库会随着网格大小的变化发生变化[15]，所以采用哈希编码将编号生成固定维度为 20 的标签，将位置坐标、编号和标签保存构造位置库。最后使用 SAQPSO 完成对 RBF-ELM 模型的训练。

表 1 不同网格划分下的定位误差

网格	算法	平均误差/m	标准差/m	运行时间/s
0.5 m×0.5 m	WKNN	0.82	1.10	1.66
	ELM	1.03	1.87	1.01
	SVM	0.90	1.71	0.98
	Bayes	1.10	2.32	0.89
	BP	1.21	2.25	0.99
	RF	1.33	2.63	0.79
1.0 m×1.0 m	WKNN	0.83	1.12	0.75
	ELM	1.08	1.94	0.08
	SVM	0.98	1.73	0.47
	Bayes	1.12	2.52	0.23
	BP	1.23	2.29	0.32
	RF	1.34	2.63	0.26
1.5 m×1.5 m	WKNN	0.88	1.19	0.67
	ELM	1.10	1.99	0.07
	SVM	1.01	1.89	0.34
	Bayes	1.10	2.49	0.20
	BP	1.28	2.58	0.31
	RF	1.36	2.89	0.24

在线预测阶段，首先在同一测试场景中随机地选择一些未知位置作为待测目标。然后在待测点采集 CSI 数据，将采集到的 CSI 数据进行指纹构造后输入训练好的 RBF-ELM 模型中，为获得更精确的定位，采用 WKNN 算法对模型输出结果与位置库中标签进行匹配。定时地在环境中采集新的校准数据完成对模型的更新，保证模型定位的稳定性[16]。

3.2　指纹构造

成年人正常行走的速度为 1.2 m/s 左右，所以在 1.0 m 网格内的停留时间大约为 0.8 s，为满足实时定位需求，用于一次定位的数据采集时间应在 0.6 s 内，采样频率选 100 Hz，可以采集到 60 个数据包的 CSI 数据进行指纹构造。由于港口环境复杂、大型设备的干扰及传输功率的变化等都会给采集到的 CSI 数据带来噪声，将所获得的 CSI 数据拆分为幅值信息和相位信息，两类信息通过不同的处理方式去除噪声干扰提取其幅值特征和相位特征，构造成位置指纹信息，具体处理过程如图 5 所示。

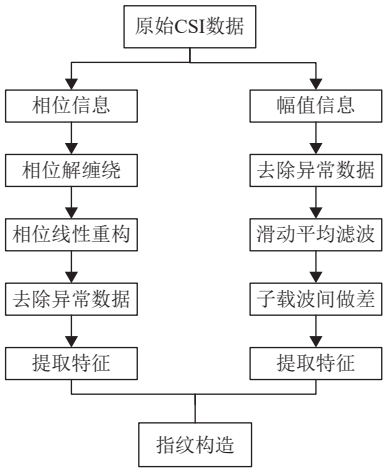
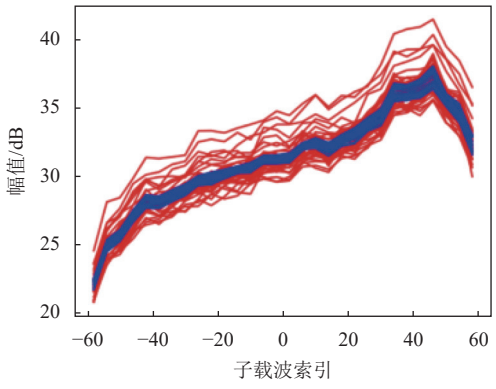
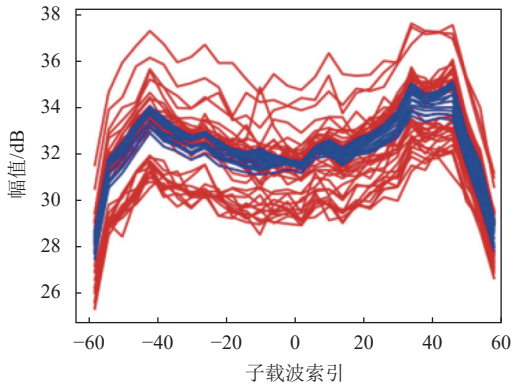


图 5　CSI 指纹构造

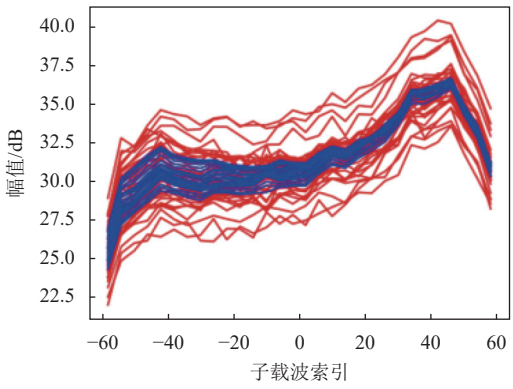
幅值信号先经过3δ准则剔除掉误差较大的数据，再使用滑动平均滤波的方式去除噪声使数据平滑，40 个数据包处理效果如图 6 所示，红色为原始数据、蓝色为处理后的。不同时间点采集并处理后的数据也会有变化，为了进一步增强指纹信息的鲁棒性，将处理后的数据运用式 (7) 计算出幅值差信息。



a. 第1根天线数据



b. 第2根天线数据

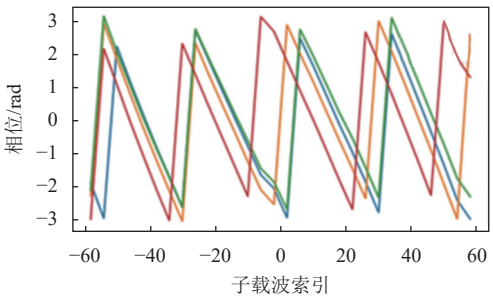


c. 第3根天线数据

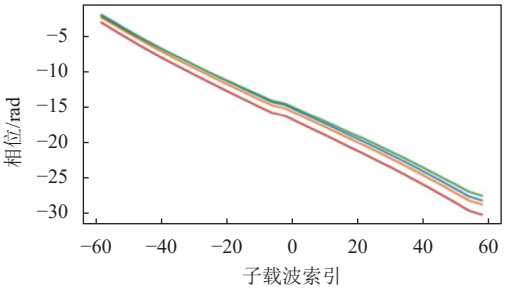
原始数据　处理数据

图 6　幅值处理效果图

由于计算机采用反正切函数来表示相位信息使得采集到的原始相位信息存在跳变，所以要进行解缠绕使相位平滑展开，再使用相位线性重构获得真实相位，相位处理如图 7 所示。



a. 原始相位



b. 解缠绕后相位

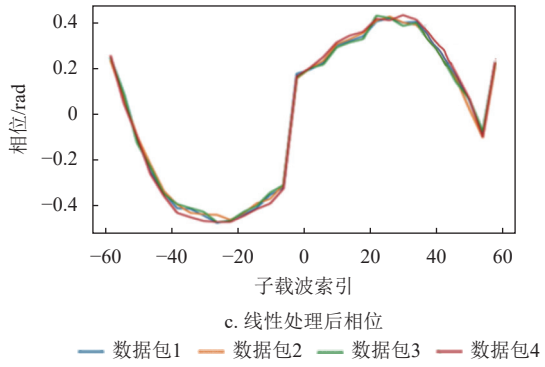


图 7 相位处理过程图

实时快速定位处理过后的幅值和相位参数过多，需要对数据做进一步特征提取减少数据量，同时避免信息丢失过多，采用主成分提取法将用于定位的幅值和相位信息维度均压缩为 3×30，再以交叉方式拼接为 1×180 作为一个位置指纹。

3.3 定位算法流程

RBF-ELM 定位模型的基本思想是利用 SAQPSO 对 RBF-ELM 中径向基层的参数进行优化使验证集可以获得更好的定位效果，提高模型的泛化性和稳定性。具体步骤如下。

1）使用指纹构造方法准备好训练集和验证集，其样本数分别为N和n。初始化粒子群、种群规模和迭代的最大次数、模拟退火的初始温度等。

2）随机产生规定的粒子群规模，每个粒子代表所有核函数中心的一种可行解，计算每个粒子适应度值，确定个体历史最优P_i和种群最优P_i。适应度计算如下：

使用训练集计算出每个粒子所对应的输出权值$\boldsymbol{\beta}$，将验证集输入模型中预测，预测位置与真实位置的平均定位误差将作为粒子的适应度。为减小过大误差的定位点存在，在适应度函数中加入误差大于 1.5 m 的个数百分比和它们的平均定位误差，表示为预测位置不在真实位置网格和其相邻的网格内，适应度表达式为：

$$f(z_i)=\overline{E}+\frac{j}{n}+0.1\overline{E}_{\max} \tag{36}$$

式中，z_i表示第i个粒子；$\overline{E}$为总体平均定位误差；j为误差大的个数；$\overline{E}_{\max}$为j个定位点的平均误差。

3）依据式 (36) 更新粒子群，计算粒子新的适应度值，判断粒子新的适应度值是否优于本身历史最优，若优于历史最优则更新，否则计算接收概率，然后产生一个[0,1]内的随机数，若产生的随机数小于计算的概率，则将此时差的位置更新为历史最优，否则不变。同理判断此时种群最优解适应度值是否优于种群的历史最优，同上进行处理，概率计算公式为：

$$p=\mathrm{e}^{-\frac{(f(z_i)-f(z_{\text{best}})}{\mathrm{K}T}}=\mathrm{e}^{-\frac{\Delta f(z)}{\mathrm{K}T}} \tag{37}$$

式中，温度T会随迭代次数的不断减小，使得算法开始前期更易接收差的解，跳出局部最优，随着温度减小，接收概率会越来越小，收敛加快。

4）判断是否获得全局最优或到达最大的迭代次数，若满足终止迭代输出最优解，否则返回第 3）步。

5）将粒子群算法输出的最优作为 RBF-ELM 的核函数中心，使用训练集计算最终输出权值$\boldsymbol{\beta}$，完成定位算法模型的建立。

6）在线定位过程中，定期或环境改变时，采集新的校准数据，依据式 (31) 对定位模型的权值动态更新，保证定位系统的稳定性。

4 实验结果及分析

4.1 实验设备和环境

实验的硬件平台主要包括 CSI 采集端（AP 基站）和数据发射端（被测人员携带的设备）。发射端为常见智能手机，支持 2.4 GHz 和 5 GHz 两种频率下工作。数据采集端为装有 Intel 5300 无线网卡的 ThinkPad X220 计算机，运行系统为 Ubuntu14.04 且装有 CSITool 工具，采集过程都在 5 GHz 的频率下进行，CSITool 工具运行于 AP 模式下。

离线阶段，被测人员会将智能手机固定于腰间站在网格中心位置进行数据采集，频率为 100 Hz，在每个网格采样 2 min 作为训练数据，期间被测人员需要转动身体改变朝向，保证数据的多样性。训练集完成后重复采集过程，每个点采集 1 min 作为验证数据。最后将采集的数据按规定个数进行分割，生成位置指纹，将指纹与标签对应制作为训练集和验证集。模拟在线阶段进行定位，测试场景中随机地选择一些位置进行预测，在每个位置上多次采集 1 s 的 CSI 数据，记录这些位置的坐标，将采集到的数据生成相应的指纹来构造测试集使用定位模型进行预测，预测结果通过匹配算法获得位置。

4.2 实验与讨论

对所提出的定位算法性能进行一系列的分析实验，并与其他一些先进的定位方法比较，数据集均采用 3.2 小节提出的指纹构造方法获得，实验处理

平台为 Python3.8。

4.2.1　实验 1

在定位算法中，隐藏层的个数m和用于定位指纹构造的数据包个数将直接影响定位模型的性能。设粒子个数为 10，最大迭代次数 50，分别对不同节点数和数据包个数进行实验，测试集的平均定位误差作为评价指标。实验结果如图 8 所示，其中列为节点个数，行为数据包数量。当隐藏层节点为 600 且使用数据包个数为 40 时可以获得最优的定位性能。在保证设备能量和数据完整的情况下，40 个数据包可以在 0.5 m 内完成采集。

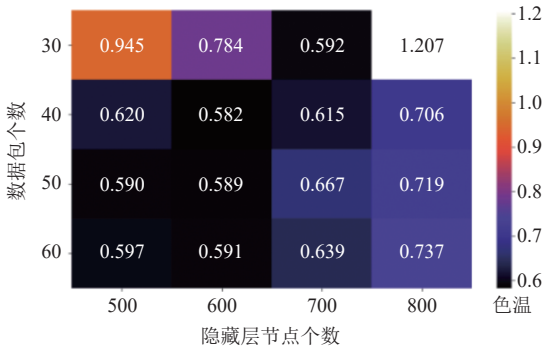


图 8　不同参数下定位性能

4.2.2　实验 2

采集设备拥有 3 根接收天线，为验证接收天线的高度对定位效果的影响，实验选择了 4 个天线离地高度进行采集数据，高度 0、1.1、1.8、3.0 m 分别表示地面、测试人员携带设备高度和测试员身高，加入误差在 1.0 m 内的定位准确度作为指标。由图 9 可以看出高度 1.1 m 获得最佳效果，这是由于设备与采集天线等高时信号减少了无规则的折射，稳定性更强，3.0 m 的定位效果次之。在实验环境中不规则扰动较少，但在实际环境中如人员走动、设备移动都会影响信号传输且高度高于 1.1 m，为提高定位系统鲁棒性选择将接收天线架设在 3.0 m 高度，减少信号传输过程中的干扰。

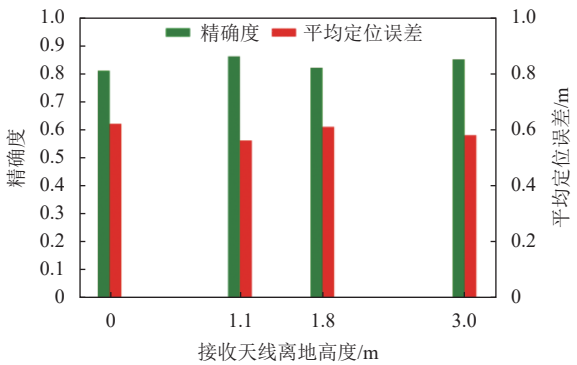


图 9　不同的天线高度定位效果图

4.2.3　实验 3

为分析所提出的 SAQPSO 算法对定位模型的优化效果，实验对比了 SAQPSO、QPSO、PSO 这 3 种优化算法效果，粒子个数和最大迭代次数都选择 10 和 50。图 10 展示了 3 种算法的适应度收敛情况，可以看到 SAQPSO 算法拥有更好的全局搜索能力，且不易陷入局部最优。

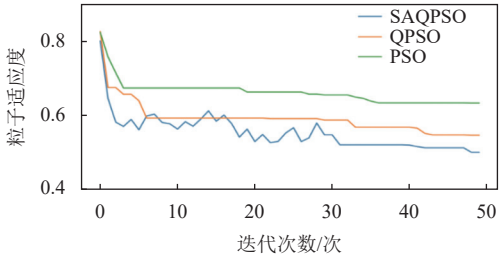


图 10　不同优化算法适应度

4.2.4　实验 4

为验证所提方法的性能，实验选取了多种传统定位算法（WKNN、ELM、SVM、Bayes、BP、RF）在两种环境下进行比较。图 11 和图 12 展示定位误差累计分布，可以看到在 LOS 的环境中有 92% 的测试点误差在 1.0 m 内，在 NLOS 的环境中有 87% 的测试点误差在 1.0 m 内，本文所提算法定位性能比其他算法更加出色。

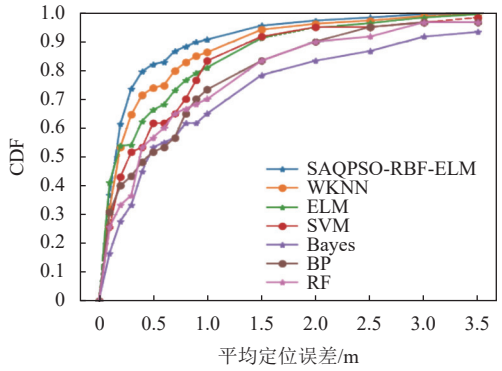


图 11　LOS 环境下定位误差 CDF 图

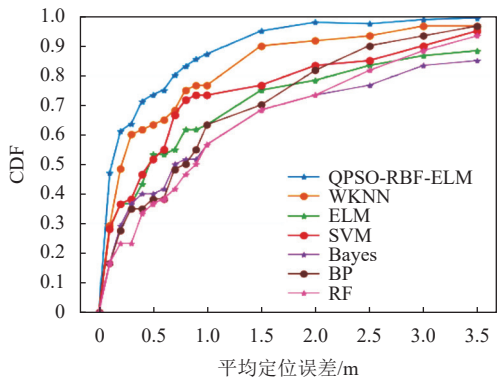


图 12　NLOS 环境下定位误差 CDF 图

在两种环境下各选择 100 个测试数据，分析各算法对这 100 个数据的定位性能。表 2 和表 3 将各算法定位效果以表格的方式进行归纳总结，并对比了各种算法的定位时效性。分析可知，在 LOS 环境下，信号传输路径没有障碍物，信号衰减较小，定位系统能够更容易地获取准确的位置信息，因此精度通常较高。在 NLOS 环境下，信号受到了多径效应、反射和衍射等影响，导致信号的质量较差。QPSO-RBF-ELM 主要依赖于优化粒子的搜索过程和训练样本的处理，而这些过程与输入数据的精度或质量（如 LOS 和 NLOS 环境下的不同）没有直接关系。即便在 NLOS 环境中，QPSO 仍会按照设定的迭代次数执行优化，RBF-ELM 的训练也会按相同方式进行。因此，虽然环境的复杂性不同，但计算流程本身并没有变化，因此两种环境下算法运行时间相同。

本文算法在 LOS 环境下可以获得 0.58 m 静态平均定位误差，在 NLOS 环境下可以获得 0.67 m 静态平均定位误差，定位运算时间为 0.08 s，相比于其他算法运行时间更短，能够满足实时定位要求，算法在定位精度和时效性上均优于其他算法。

表 2　LOS 环境下各算法总结

定位算法	平均误差/m	标准差/m	运行时间/s
QPSO-RBF-ELM	0.58	0.83	0.08
WKNN	0.83	1.12	0.75
ELM	1.08	1.94	0.08
SVM	0.98	1.73	0.47
Bayes	1.12	2.52	0.23
BP	1.23	2.29	0.32
RF	1.34	2.63	0.26

表 3　NLOS 环境下各算法总结

定位算法	平均误差/m	标准差/m	运行时间/s
QPSO-RBF-ELM	0.67	1.22	0.08
WKNN	0.98	1.95	0.77
ELM	1.34	2.79	0.08
SVM	1.17	2.18	0.46
Bayes	1.68	3.24	0.21
BP	1.54	3.16	0.31
RF	1.92	3.43	0.29

4.2.5　实验 5

为验证模型的动态定位性能，测试人员以正常行走速度在 LOS 定位区域内分别沿着矩形和直线行走采集数据进行定位，定位效果如图 13 所示，蓝色为人员行走轨迹，红色为定位结果。其中矩形轨迹的动态定位误差为 1.04 m，直线的动态定位误差为 0.86 m。

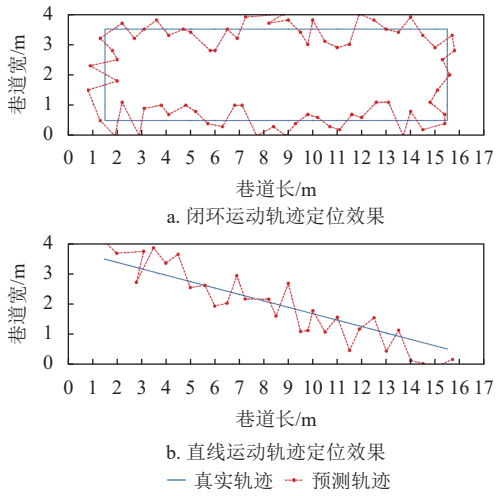


图 13　动态定位效果图

4.2.6　实验 6

为分析定位环境发生变化后，原定位模型和权值更新后模型的性能，实验选择改变定位环境中的信噪比（SNR）来模拟港口环境发生变化，SNR 取 0、10、20、30、40 dB。在信噪比为 0 的环境下训练好定位模型，在其他信噪比的环境下采集部分位置数据用以更新模型权值。图 14 展示了原模型和权值更新后模型在不同环境下的定位性能，可以看到随着信噪比的变化，原模型定位性能衰退比较严重，及时采集新的校准数据更新权值可以有效减少系统定位性能衰退，保证了系统的长期稳定性。

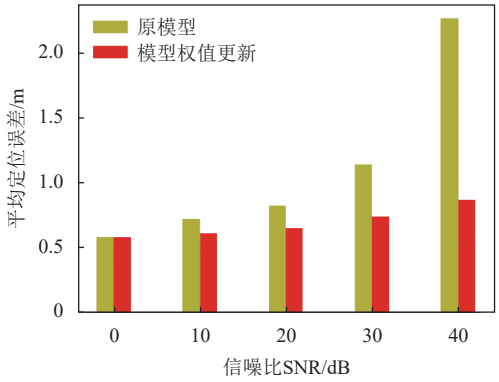


图 14　不同信噪比下定位性能

4.2.7　实验 7

在实验场景下对定位系统进行整体性能测试，并与文献 [17-20] 中的定位系统进行性能比较。定

位误差分布如图 15 所示，平均定位误差分别为 0.58、0.73、0.83、1.06、1.12 m，综合对比本文算法在精度、时效性和稳定性上都优于其他算法。

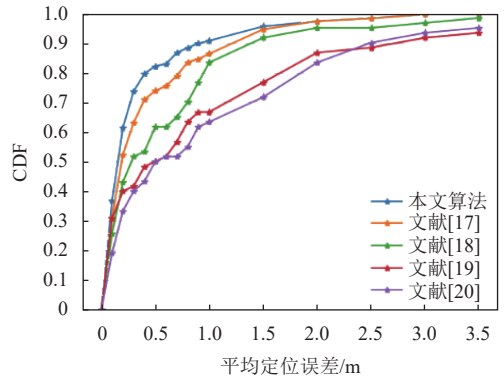


图 15　各算法定位误差 CDF 图

4.2.8　实验 8

在港口定位环境中，仅考虑单目标定位往往无法充分反映算法的应用性能和可靠性，尤其是当多个目标同时存在时。因此，为了验证所提 QPSO-RBF-ELM 算法的可靠性，设计多目标定位实验，在模拟港口环境中进行多个目标的同时定位。其中圆圈代表真实目标，菱形与十字分别代表文献 [13] 与 QPSO-RBF-ELM 的定位位置。

由图 16 可以直观地验证 QPSO-RBF-ELM 算法在多目标定位方面的应用效果，这不仅可以展示算法的优越性能，还可以为实际应用中多目标定位的系统优化提供依据。

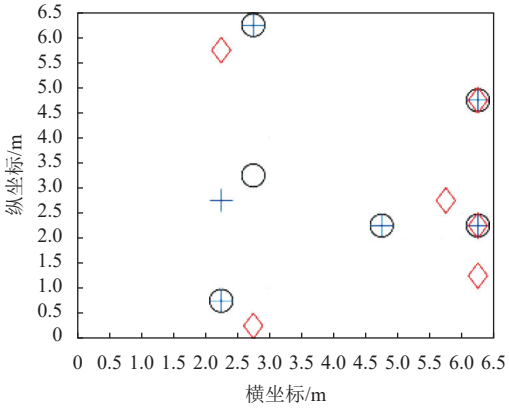


图 16　多目标定位效果图

5　结束语

本文采用信道状态信息（CSI）作为指纹，仅使用一个 AP 基站就可实现指纹定位，为解决因港口 AP 稀疏分布无法实现高精度指纹定位提供新思路。结合 RBF 的全局逼近特性和 ELM 的计算简单、运行速度快、可在线学习等优点搭建定位模型，解决离线指纹存储和匹配速度慢等缺点。使用 SAQPSO 对模型参数优化，进一步提升了模型的定位性能和泛化能力。采用哈希编码对网格编号编码，解决因网格数目过多和变化所引起的模型适用性，并在在线定位阶段采用了 WKNN 匹配算法，实现港口目标的精确定位。

将粒子群优化与遗忘在线顺序学习结合起来，解决了传统 RBF-ELM 在港口定位中的不足。粒子群可以用于优化 RBF-ELM 中的隐含层参数，而遗忘在线顺序学习针对数据流在在线学习中的数据变化的问题进行优化，增强了 RBF-ELM 在实时学习中的表现。同时，遗忘机制可以帮助模型及时忘记过时的或不再相关的数据，从而提高模型在动态数据环境中的泛化能力；通过将遗忘机制结合到 RBF-ELM 中，尤其是在粒子群优化的支持下，能够在数据流的背景下提供有效的训练方案。通常，传统的 RBF-ELM 在面对不断变化的数据时容易受到老旧信息的干扰，通过引入这些机制，有效地解决了这一问题。

参 考 文 献

[1] 施晓冬, 姜昊舟. 港口智能水平运输设备感知和定位系统[J]. 港口装卸, 2023(4): 46-49.
SHI X D, JIANG H Z. Perception and positioning system for intelligent horizontal transportation equipment in ports[J]. Port Handling, 2023(4): 46-49.

[2] 黄庭. 基于北斗高精度定位的智慧港口创新应用[J]. 中国港口, 2023(9): 58-61.
HUANG T. Innovative applications of smart ports based on Beidou high-precision positioning[J]. China Ports, 2023(9): 58-61.

[3] 王鹏, 庄肃凯, 刘雷. 基于 5G+的人员定位系统在港口安全管理中的应用[J]. 设备管理与维修, 2023(8): 124-125.
WANG P, ZHUANG S K, LIU L. Application of 5G+ based personnel positioning system in port safety management[J]. Equipment Management and Maintenance, 2023(8): 124-125.

[4] 杨勇生, 迟景成, 姚海庆. 基于模糊 Kalman 滤波的港口车辆组合定位方法研究[J]. 全球定位系统, 2020, 45(6): 80-85.
YANG Y S, CHI J C, YAO H Q. Research on the combined positioning method of port vehicles based on fuzzy Kalman filtering[J]. Global Positioning System, 2020, 45(6): 80-85.

[5] 邵小强, 李康乐, 陈熙, 等. 基于改进卡尔曼滤波和参数拟合的矿井 TOA 定位方法[J]. 煤炭学报, 2019, 44(5): 1616-1624.
SHAO X Q, LI K L, CHEN X, et al. Mine TOA positioning method based on improved Kalman filtering and parameter

fitting[J]. Journal of China Coal Society, 2019, 44(5): 1616-1624.

[6] GUO X C, XIA P P. Mine personnel location system based on Internet of Things[J]. IOP Conference Series: Materials Science and Engineering, 2018, 439: 032087.

[7] 宋明智. 矿井 WLAN 位置指纹定位中的关键问题研究[D]. 徐州: 中国矿业大学, 2020.
SONG M Z. Research on key issues in mine WLAN fingerprint positioning[D]. Xuzhou: China University of Mining and Technology, 2020.

[8] 宋明智, 钱建生, 胡青松. 基于 AKPCA 算法的井下 WLAN 位置指纹定位[J]. 煤炭科学技术, 2022, 50(3): 248-256.
SONG M Z, QIAN J S, HU Q S. Underground WLAN fingerprint positioning based on AKPCA algorithm[J]. Coal Science and Technology, 2022, 50(3): 248-256.

[9] YANG Z, ZHOU Z M, LIU Y H. From RSSI to CSI[J]. ACM Computing Surveys, 2013, 46(2): 1-32.

[10] 张大庆, 张扶桑, 吴丹, 等. 基于 CSI 的通信感知一体化设计: 问题、挑战和展望[J]. 移动通信, 2022, 46(5): 9-16.
ZHANG D Q, ZHANG F S, WU D, et al. Integrated design of communication sensing based on CSI: Issues, challenges, and prospects[J]. Mobile Communications, 2022, 46(5): 9-16.

[11] 王旭东, 刘帅, 吴楠. CAEFi: 基于卷积自编码器降维的信道状态信息指纹室内定位方法[J]. 电子与信息学报, 2022, 44(8): 2757-2766.
WANG X D, LIU S, WU N. CAEFi: Indoor positioning method based on convolutional autoencoder dimensionality reduction of channel state information fingerprint[J]. Journal of Electronics and Information Technology, 2022, 44(8): 2757-2766.

[12] LI Q, LIAO X W, LIU M M, et al. Indoor localization based on CSI fingerprint by Siamese convolution neural network[J]. IEEE Transactions on Vehicular Technology, 2021, 70(11): 12168-12173.

[13] 王博远, 刘学林, 蔚保国, 等. WiFi 指纹定位中改进的加权 k 近邻算法[J]. 西安电子科技大学学报（自然科学版）, 2019, 46(5): 41-47.
WANG B Y, LIU X L, WEI B G, et al. Improved weighted k-nearest neighbor algorithm in WiFi fingerprint positioning[J]. Journal of Xi'an University of Electronic Science and Technology (Natural Science Edition), 2019, 46(5): 41-47.

[14] 刘星, 王文双, 赵建印, 等. 自适应在线增量 ELM 的故障诊断模型研究[J]. 系统工程与电子技术, 2021, 43(9): 2678-2687.
LIU X, WANG W S, ZHAO J Y, et al. Research on fault diagnosis model based on adaptive online incremental ELM[J]. System Engineering and Electronics, 2021, 43(9): 2678-2687.

[15] 张兆娟, 王万良, 唐继军. 适应度二次选择的 QPSO 和 SA 协同搜索大规模离散优化算法[J]. 通信学报, 2020, 41(8): 22-31.
ZHANG Z J, WANG W L, TANG J J. Collaborative search large-scale discrete optimization algorithm based on QPSO and SA with fitness secondary selection[J]. Journal on Communications, 2020, 41(8): 22-31.

[16] CAO W P, MING Z, XU Z W, et al. Online sequential extreme learning machine with dynamic forgetting factor[J]. IEEE Access, 2019, 7: 179746-179757.

[17] 张雷. 基于 CSI 的煤矿井下定位方法研究[D]. 徐州: 中国矿业大学, 2019.
ZHANG L. Research on CSI-based underground positioning method for coal mines[D]. Xuzhou: China University of Mining and Technology, 2019.

[18] ZHANG L, HU Y J, LIU Y F, et al. WiCLoc: A novel CSI-based fingerprint localization system[J]. International Journal of Pattern Recognition and Artificial Intelligence, 2020, 34(4): 2058003

[19] LIU W, WANG X, DENG Z L. CSI amplitude fingerprinting for indoor localization with dictionary learning[J]. Entropy, 2021, 23(9): 1164.

[20] LI H H, ZENG X S, LI Y Z, et al. Convolutional neural networks based indoor Wi-Fi localization with a novel kind of CSI images[J]. China Communications, 2019, 16(9): 250-260.

责任编辑 张 莉