

基于改进 ELM 的煤矿井下定位算法

金浩, 孙运全, 杨海晶

(江苏大学 电气信息工程学院, 江苏 镇江 321100)

摘要: 提出了一种基于改进极限学习机 (ELM, extreme learning machine) 神经网络的煤矿井下人员定位算法, 针对测距模型易受井下复杂环境干扰, 无法准确测距的问题, 选用基于指纹的位置匹配模型; 使用极限学习机将指纹和位置进行匹配, 选用改进鲸鱼优化算法 (IWOA, improved whale optimization algorithm) 选取 ELM 合适的输入权值和隐含层阈值, 以提高定位精度。在定位的在线阶段, 将新的指纹数据代入带动态权值因子的在线顺序极限学习机 (DOS-ELM, dynamic weight factor online sequential extreme learning machine) 模型对定位模型进行动态调整, 以克服电磁传播环境变动使定位结果产生的误差; 仿真实验结果表明, 该模型的定位误差在 1.5 m 以内的置信概率为 72%, 平均定位误差为 1.64 m, 与其他算法的实验结果相比, 文章算法鲁棒性强, 定位精度高。

关键词: 井下人员定位; 改进鲸鱼优化算法; 极限学习机; 在线序列方法; 自适应定位

Coal Mine Underground Positioning Algorithm Based on Improved Elm

JIN Hao, SUN Yunquan, YANG Haijing

(School of Electrical and Information Engineering, Jiangsu University, Zhenjiang 321100, China)

Abstract: An adaptive location algorithm based on the improved extreme learning machine (ELM) neural network is proposed. Aiming at the problem that the ranging model is easily disturbed by the complex underground environment and the ranging error is large, the fingerprint based location matching model is selected. ELM is used to match fingerprint and location. Improved whale optimization algorithm (IWOA) is used to select ELM's appropriate input weight and hidden layer threshold to improve positioning accuracy. In the online stage of localization, the new fingerprint data is substituted into the dynamic weight factor online sequential extreme learning machine (DOS-ELM) model with dynamic weight factor to dynamically adjust the localization model, so as to overcome the error caused by the change of electromagnetic propagation environment. The simulation results show that the confidence probability of the positioning error within 1.5 m is 72%, and the average positioning error is 1.69 m. Compared with the experimental results of other algorithms, this algorithm has strong robustness and high positioning accuracy.

Keywords: underground personnel positioning; improved whale optimization algorithm; extreme learning machine; online sequence method; adaptive location

0 引言

为了提高井下生产调度管理的效率以及减少煤矿事故带来的损失, 需要对井下人员定位技术做进一步

研究。目前在煤矿生产中广泛应用的井下人员定位系统大多数是基于射频识别 (RFID, radio frequency identification) 技术开发的, 这些系统普遍无法达到

收稿日期:2021-06-21; 修回日期:2021-07-23。

基金项目:中国博士后面上基金项目(20110491358);江苏大学高级人才研究项目(13DG054)。

作者简介:金浩(1997-),男,江苏沭阳人,硕士研究生,主要从事智能算法及矿井人员定位方向的研究。

孙运全(1969-),男,山东莒南人,博士,硕士生导师,教授,主要从事电力系统配电自动化终端设备方向的研究。

引用格式:金浩,孙运全,杨海晶. 基于改进 ELM 的煤矿井下定位算法[J]. 计算机测量与控制, 2022, 30(1): 202-208.

较高定位精度, 只能确定人员所在的大致区域, 而国有大型煤矿在智能化发展过程中将会把有线无线一体化网络作为移动通信系统的主流技术^[1], 这就为利用接收信号强度指示 (RSSI, received signal strength indication)^[2] 实现更高精度的井下人员定位奠定了基础。

基于 RSSI 的定位算法主要包括两种, 一是直接测距, 即根据 RSSI 的数值直接确定目标节点与信标节点之间的距离, 得到目标节点的相对位置。二是位置指纹方法, 即确立 RSSI 值与位置的直接映射关系, 而不必确定目标节点与信标节点之间的距离。由于井下环境复杂, 信号传播过程中不可避免地受到衰落、阴影以及多径效应的影响, 直接测距的方法精度不高, 所以位置指纹方法逐渐成为了当前研究的主流。

文献 [3] 使用模拟退火算法优化 RBF 神经网络的结构, 并将其应用于无线定位问题中。文献 [4] 使用启发式算法优化神经网络, 建立 RSSI 值与位置的直接映射关系。文献 [5] 提出基于极限学习机的定位算法, 通过对比测试, 发现其定位效果好于 BP 等其他神经网络定位算法。文献 [6] 使用了鲸鱼算法优化神经网络的结构, 在避免局部最优和收敛速度上表现良好。文献 [7] 使用迁移学习的方式使定位算法适应室内环境的变化, 将上个时间段提取的特征迁移到下一个时间段使用。这一构想还不能适应环境变化更为复杂的井下。文献 [8] 根据参考基站实时 RSSI 更新指纹地图。这种方法可以使用较少的参考基站, 降低了对硬件的要求。但由于算法的复杂度太高, 定位的速度慢, 无法满足井下实时定位的要求。

以上研究表明采用智能算法优化神经网络能够准确高效地进行在复杂环境下的定位, 本文提出了改进鲸鱼算法优化极限学习机的井下人员定位模型。

在离线训练阶段, 将煤矿井下参考节点接收到的 RSSI 值作为神经网络的输入, 将参考节点的位置坐标作为网络输出, 以此训练 ELM 神经网络, 获得 RSSI 值与节点坐标之间的网络模型。为了提高 ELM 神经网络的泛化能力, 采用改进鲸鱼算法为 ELM 选取合适的权值和阈值, 构建了 IWOA-ELM 初始定位模型。在线定位阶段则引入带动态权值因子的在线连续学习方法, 首先接收采集实时位置指纹数据, 代

入初始定位模型中, 对其进行动态调整。然后利用无线信号接收装置接收目标点的 RSSI 指纹数据, 代入到调整后的模型中, 计算出目标节点的估计位置坐标。定位环境如图 1 所示。

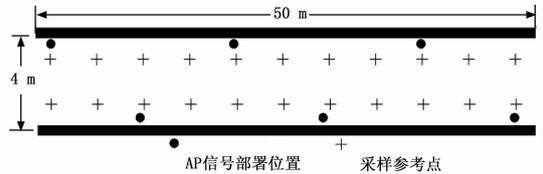


图 1 定位环境示意图

综上, 本文主要针对 ELM 神经网络输入权值和隐含层阈值取值难以以及环境时变性影响定位精度等问题, 改进定位算法, 提高了定位效果。

1 IWOA-ELM 神经网络算法实现

1.1 ELM 神经网络算法

极限学习机 (ELM, extreme learning machine) 是由文献 [8] 提出的一种单隐含层前馈神经网络 (SLFN, single hidden layer feedforward neural network)。该神经网络包括输入层、隐含层、输出层三层结构 (如图 2 所示)。

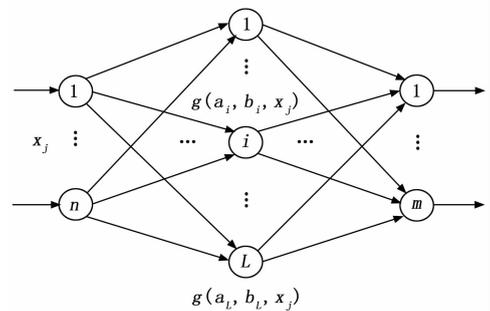


图 2 ELM 神经网络结构

ELM 不依赖于梯度下降, 学习速度比 BP (back-propagation) 算法等传统前馈网络快, 对于大量及非线性样本也具有很好的适用性^[9-10]。

ELM 需要设置隐含层神经元的个数, 而输入层与隐含层之间的权值和隐含层的阈值则随机产生, 然后利用最小二乘法解方程组得到输出权值。

对于训练集中 N 个位置指纹数据 (x_i, t_i) , 其中输入向量为 $\mathbf{x}_i = [x_{i1}, x_{i2}, \dots, x_{im}]$, 输出向量为 $\mathbf{t}_i = [t_{i1}, t_{i2}, \dots, t_{im}]^T$ 。设 ELM 位置估计模型的输入层节点个数为 n , 隐含层节点, 个数为 L , 输

出层节点个数为 m ，该模型如下所示：

$$y_j = \sum_{i=1}^1 \beta_i \sigma_i(\omega_i x_j + v_j), j = 1, 2, \dots, q \quad (1)$$

式中， σ 为激活函数，以激活函数将样本映射到另一个特征空间，得到矩阵 H ，

$$H\beta = T \quad (2)$$

在新的特征空间下，利用最小二乘法便可求解出最优输出权值 β ：

$$\beta^* = H^+ T \quad (3)$$

式中， β^* 为输出权重， H^+ 为矩阵 H 的 Moore-Penrose 广义逆。

1.2 WOA 算法

鲸鱼优化算法是受到座头鲸捕食行为启发的一种启发式算法，鲸鱼包围目标猎物的时候，假设当前的最佳候选解是目标猎物位置或最靠近猎物的位置。然后会不断更新其位置^[11]，这种狩猎行为可以用如下数学公式表示：

$$D = |CX^*(t) - X(t)| \quad (4)$$

$$X(t+1) = X^*(t) - AD \quad (5)$$

其中： D 为包围步长， t 表示当前迭代次数， $X^*(t)$ 是是目前得到的最优解的位置向量， $X(t)$ 为当前位置向量，如果在迭代中出现更优解，那么位置向量 $X^*(t)$ 也要随之更新。 A 和 C 是系数向量，由如下公式得出：

$$\begin{cases} a = 2 - \frac{2t}{t_{max}} \\ A = 2ar - a \end{cases} \quad (6)$$

$$C = 2r \quad (7)$$

其中： a 在迭代过程中从 2 线性下降到 0， t_{max} 是最大迭代次数。 r 是区间内的随机向量。

算法模拟鲸鱼通过气幕袭击和随机搜索的捕食过程进行迭代，寻找最优鲸鱼种群适应度值，该阶段可以用如下公式表示：

$$L(t+1) = \begin{cases} L^*(t) - AD_1 & |A| < 1, p < 0.5 \\ L_{rand}(t) - AD_2 & |A| > 1 \\ L^*(t) - D_3 e^{bl} \cos(a\pi l) & |A| < 1, p \geq 0.5 \end{cases} \quad (8)$$

$$\begin{aligned} D_1 &= |CL^*(t) - L(t)| \\ D_2 &= |CL_{rand}(t) - L(t)| \\ D_3 &= |L^*(t) - L(t)| \end{aligned} \quad (9)$$

式中，当 $|A| < 1$ 时，鲸鱼向猎物发起攻击，攻击

方式取决于取值范围为 $[0, 1]$ 的随机数 ρ ，当 $\rho < 0.5$ 时采用收缩包围机制更新空间位置，当 $\rho \geq 0.5$ 时则采用螺旋式位置更新机制。当 $|A| > 1$ 时鲸鱼群则用随机的方式更新位置进行搜索捕食，这样可以保证算法对于全局的搜索。

WOA 算法简洁易实现、参数设置少、寻优性能强，然而，基本 WOA 算法仍然存在不足，由相关文献[12]分析可知，由于收敛因子 a 在迭代过程中线性递减，算法的全局搜索能力也随之下降，到了迭代后期群体中所有个体均向最优个体聚集，导致群体多样性缺失，易使算法陷入局部最优^[13-14]。为了解决上述问题，本文引入多样性变异操作改善 WOA 算法性能，使算法能避免早熟收敛，得到全局最优解。

1.3 IWOA-ELM 神经网络算法

IWOA 算法的基本思想是将多样性变异操作引入 WOA 算法中，假设最优个体 $X_i = (x_{i1}, x_{i2}, \dots, x_{id})$ ，从个体中随机选取一个元素 $x_k (k=1, 2, \dots, d)$ ，然后进行如下式所示的变异：

$$X'_i = \begin{cases} l_i + \lambda \cdot (u_i - l_i), & i = k \\ X_i, & \text{otherwise} \end{cases} \quad (10)$$

其中： λ 为取值范围 $[0, 1]$ 的随机数， u_i 和 l_i 分别为变量 X_i 的上界和下界。

对最优鲸鱼个体的多样性变异操作，避免了算法出现早熟收敛，最终收敛到全局最优解。

IWOA-ELM 算法的基本思想是利用 IWOA 算法对 ELM 的权值和阈值进行优化，发挥 IWOA 算法的全局寻优能力，提高 ELM 神经网络的泛化能力。IWOA-ELM 算法流程如下。

Step1: 设置 IWOA 算法的参数，鲸鱼种群规模 sizepop，迭代次数 maxgen，鲸鱼种群的位置上界和下界 ub 和 lb ；

Step2: 将优化目标 ELM 得出的定位平均误差 E 作为鲸鱼个体适应度值，表达式如下：

$$E(i) = \sqrt{(x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2} \quad (11)$$

$$\bar{E} = \frac{\sum_{i=1}^n E(i)}{n} \quad (12)$$

其中： (x_i, y_i) 和 (\hat{x}_i, \hat{y}_i) 分别为估算位置和实际位置。

对每个个体的适应度值进行排序，得到最佳鲸鱼个体及位置，并将其记录；

Step3: 根据收敛因子更新公式计算收敛因子 a 的值;

Step4: 计算其他参数 A , C , l 和 p , 判断概率 P 的值是否小于 0.5, 若是, 则转入 Step5, 否则搜索个体按照公式以螺旋运动的方式向猎物进行攻击;

Step5: 判断参数 A 的值是否小于 1, 若是, 搜索个体则按照公式对猎物进行收缩包围, 否则搜索代理根据公式进行全局搜索;

Step6: 此时位置更新完毕, 再次计算每个搜索个体求解目标函数的适应度值, 并与先前保留的最佳搜索代理的位置信息 X 进行比较, 若优于 X . 对 X 位置信息进行替换;

Step7: 对当前最优个体进行多样性变异操作, 计算个体的适应度值, 更新最优解;

Step8: 比较当前迭代次数与设定值, 若达到设定值, 终止迭代, 输出当前最优解 (即 ELM 的最优权值和阈值), 否则返回 Step3;

Step9: 将 IWOA 算法输出的最优解映射为 ELM 神经网络的初始权值和阈值, 用训练样本集训练 ELM 神经网络, 完成井下定位算法模型建立。

2 动态校准方法

为了在井下电磁环境随时间变动的情况下, 保证定位系统的精度, 就需要根据环境的变化, 及时对定位模型进行校准。因此, 本文在原有 IWOA-ELM 算法的基础上, 引入在线连续学习方法^[15], 使得初始定位模型能够根据在线阶段更新的动态校准数据得到调整。

H 的 Moore-Penrose 广义逆 H^+ 为:

$$H^+ = (H^T H)^{-1} H^T \quad (13)$$

所以初始定位模型的输出权值矩阵如公式所示:

$$\beta^{(0)} = H_0^+ T_0 = (H_0^T H_0)^{-1} H_0^T T_0 = K_0^{-1} H_0^T T_0 \quad (14)$$

式中, $K_0 = H_0^T H_0$, 在此基础上再输入一组在线校准数据集 (X_1, T_1) , 输出权值矩阵变为:

$$\beta^{(1)} = K_1^{-1} \begin{bmatrix} H_0 \\ H_1 \end{bmatrix}^T \begin{bmatrix} T_0 \\ T_1 \end{bmatrix} \quad (15)$$

式中, $K_1 = \begin{bmatrix} H_0 \\ H_1 \end{bmatrix}^T \begin{bmatrix} H_0 \\ H_1 \end{bmatrix} = K_0 + H_1^T H_1$, 对其重写后为:

$$\begin{bmatrix} H_0 \\ H_1 \end{bmatrix}^T \begin{bmatrix} H_0 \\ H_1 \end{bmatrix} = H_0^T Y_0 + H_1^T Y_1 =$$

$$K_1 \beta^{(0)} - H_1^T H_1 \beta^{(0)} + H_1^T Y_1 \quad (16)$$

则式 (15) 可改写为:

$$\beta^{(1)} = \beta^{(0)} + K_1^{-1} H_1^T (T_1 - H_1 \beta^{(0)}) \quad (17)$$

那么, 当第 $k+1$ 组数据输入时, 输出权值矩阵为:

$$\beta^{(k+1)} = \beta^{(k)} + K_{k+1}^{-1} H_{k+1}^T (T_{k+1} - H_{k+1} \beta^{(k)}) \quad (18)$$

式中, $K_{k+1} = K_k + H_{k+1}^T H_{k+1}$ 。

从式 (18) 中可以看出, 当定位模型中输入新的指纹数据时, 不需要再将此前的数据重新纳入训练范围, 算法的计算量由此没有大幅增长。同时定位模型也根据新增数据得到了修正, 兼顾了效率和环境适应性。

但是在对式 (18) 进一步分析后发现, 式中旧模型和新增调整量的权重系数是相同的 (均为 1), 而事实上, 在井下环境随时变动的情况下, 就要求定位模型能尽快适应这种变化, 调整好旧有模型和新增调整量的相对重要性^[16]。所以本文在式 (15) 中加入动态权值因子, 将式 (15) 改为:

$$\beta^{(1)} = (\lambda^2 H_0^T H_0 + H_1^T H_1)^{-1} \begin{bmatrix} \lambda H_0 \\ H_1^T \end{bmatrix} \begin{bmatrix} \lambda T_0 \\ T_1 \end{bmatrix} \quad (19)$$

那么式 (18) 的 K_{k+1} 变为 $\lambda^2 K_k + H_{k+1}^T H_{k+1}$, 权值因子依照如下公式迭代:

$$\lambda = \lambda - \frac{1}{5\pi} \text{atan}(E) \quad (20)$$

式中, E 为调整前后模型的精度之差, 由于环境的变化是连续且相对稳定的, 所以选择平滑性好的 \arctan 作为激活函数, 同时通过测试, 确定当 \arctan 的放大系数为 $1/5\pi$ 时能够使调整后的模型达到最高定位精度。

3 井下定位算法流程

井下定位算法分为离线训练阶段和在线定位阶段两个部分。在离线训练阶段, 首先利用无线信号接收装置采集初始阶段的位置指纹数据, 然后用采集好的数据集训练 IWOA-ELM 神经网络。建立 IWOA-ELM 神经网络定位模型, 具体流程如图 3 所示。

在线定位阶段, 首先接收采集实时位置指纹数据, 代入初始定位模型中, 对其进行动态调整。然后利用无线信号接收装置接收目标点的 RSSI 指纹数据, 代入到调整后的模型中, 计算出目标节点的估计位置坐标。具体流程如图 4 所示。

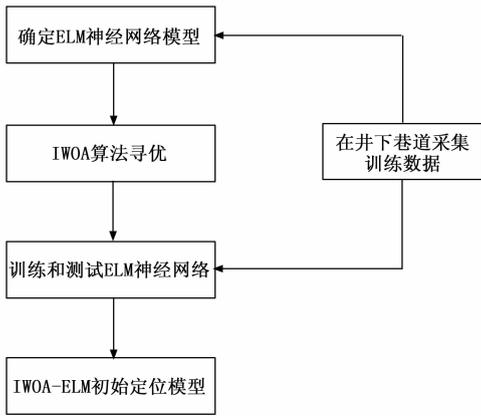


图 3 在线训练流程

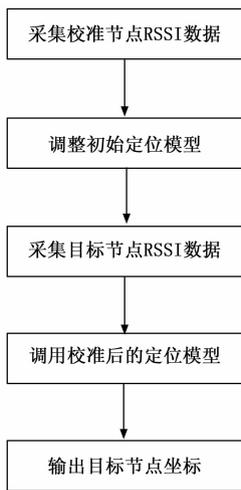


图 4 实时定位流程

4 实验分析

4.1 实验设计

本文使用 MATLAB 对井下场景的射线跟踪进行仿真^[17-19]，生成用于测试的指纹数据库。实验的仿真平台为 MATLAB 2016b，电脑配置为 Core i5 处理器、8 GB 内存。该指纹数据库设定为 50 m×4 m 的狭长空间，其中分布有 6 个 AP 节点，由 ITU 传播模型^[20]来构建，其表达式如下：

$$PL(d) = PL_0 - 10\alpha \log(d) + X_s \quad (21)$$

式中， PL_0 是路径损耗系数， X_s 是均值为零的随机噪声， α 是路径衰减指数。构建完成的指纹数据库包括 10 000 组离线训练数据、1 000 组增量训练数据以及 90 组在线测试数据，部分训练数据如表 1 所示。

实验分为两部分：第一部分是在环境不变的情况下验证初始定位模型的性能，而第二部分则是在环境

表 1 部分训练数据

信号强度单位：dBm

(X, Y)	AP1	AP2	AP3	AP4	AP5	AP6
(33.0, 2.2)	-71	-62	-53	-45	-52	-53
(6.9, 2.0)	-68	-43	-54	-62	-59	-67
(25.2, 2.5)	-68	-52	-50	-47	-51	-60
(13.9, 1.5)	-54	-43	-49	-50	-73	-64
—	-56	-44	-51	-59	-61	-64
—	-52	-32	-59	-56	-63	-63
...

变化情况下验证定位模型对环境变化的适应能力。对定位模型性能的评判标准为定位平均误差和不同误差距离下的置信概率。

根据实验中采集的训练数据集，对 IWOA-ELM 神经网络的初始参数进行设置，由于一组数据中包含 6 个 RSSI 值，所以输入层节点数为 6。分别对 sin, hardlim 和 sigmoid 函数进行测试对比后发现，激活函数选择 sigmoid 函数时，定位结果最稳定，误差也相对小。如图 5 所示，其他条件相同时，在测试中确定当隐含层节点数为 700，定位误差最小。

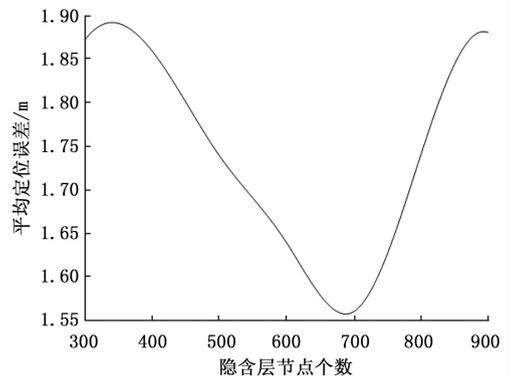


图 5 不同隐含层节点个数下的定位误差

4.2 初始定位模型性能评估

为了能够直观地展示本文提出的定位算法性能，使用同样的训练数据和测试数据代入不同定位模型。并对其结果进行对比分析，其中包括 BP, ELM, WOA-ELM 和 IWOA-ELM。使用的数据为离线阶段在同一环境中采集的同一时段的测量数据。部分定位结果如图 6 所示。

由图中数据可以计算出各个定位算法的定位平均误差 \bar{E} ，如表 2 所示，从表和图中的数据可以看出，

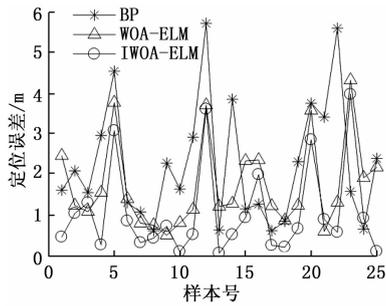


图 6 初始定位模型性能对比

相比于 BP, WOA-ELM, ELM 算法, 本文提出的 IWOA-ELM 定位算法的误差更小, 定位精度更高。而且处理同样的训练数据, IWOA-ELM 的收敛速度更快, 达到相同精度所需时间更少。

表 2 各定位模型的定位平均误差

定位算法	BP	ELM	WOA-ELM	IWOA-ELM
平均误差/m	3.23	1.87	1.76	1.56

4.3 环境变化后的定位模型性能评估

针对煤矿井下环境时变特性使定位精度随时间下降的问题, 首先改变式 (21) 中的参数 σ , 获得在线阶段变化后的位置指纹数据, 然后将数据代入初始定位模型, 利用带动态权值因子的在线序列方法对初始定位模型修正获得本文模型 (IWOA-DOS-ELM), 最后分别对初始定位模型 (IWOA-ELM) 在线序列修正的初始定位模型 (IWOA-OS-ELM) 以及本文模型进行测试, 测试结果如图 7 所示。

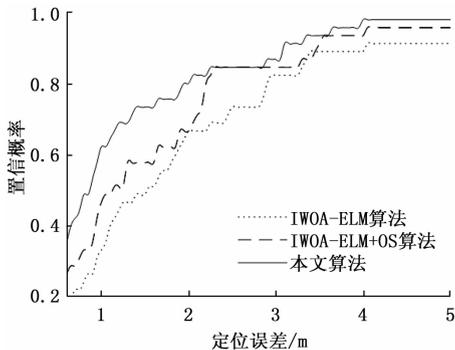


图 7 三种算法的性能对比

从图 7 可以看出, 本文算法在误差为 1.5 m 以内的置信概率是 72%, 而 IWOA-OS-ELM 算法和 IWOA-ELM 的置信概率分别只有 56% 和 50%, 在限定误差为 1.5 m 时, IWOA-OS-ELM 算法和本文算法的准确率相对于 IWOA-ELM 要高 6% 和

22%, 这是因为前两个模型针对环境变化做出了一些适应性的改进, 而本文算法比 IWOA-OS-ELM 算法的准确率还要高 16%, 这是因为本文算法加入了动态权值因子, 使算法模型的改进更能适应环境。

由图 8 可知, 定位模型经动态调整后, 输出的定位坐标更加接近于实际坐标, 定位精度得以提高。计算校准前后的定位平均误差可得, 未经校准的 IWOA-ELM 算法的定位平均误差为 2.25 m, 经过校准后的 IWOA-ELM 算法的定位平均误差为 1.64 m, 定位精度提高了, 验证了动态校准法更加适应随时间变化的煤矿井下环境, 能够满足井下自适应定位要求。

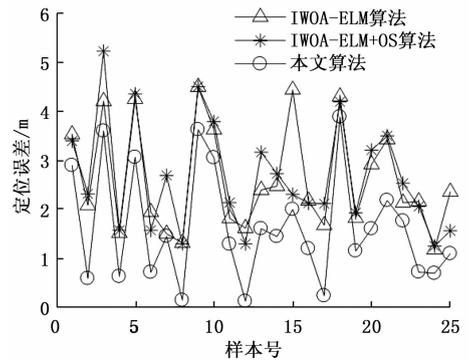


图 8 模型校准性能对比

图 9 将三个时间段中 IWOA-ELM、IWOA-OS-ELM、IWOA-DOS-ELM 三种算法的平均定位误差进行对比。时间段 0、1、2 分别代表发生环境变化的次数, 可以发现在第一次环境变化之前, 定位精度非常接近。但是在环境变化之后, 可以看出通过本文提出的动态校准方法, 本文算法的鲁棒性最强, 定位误差最小。

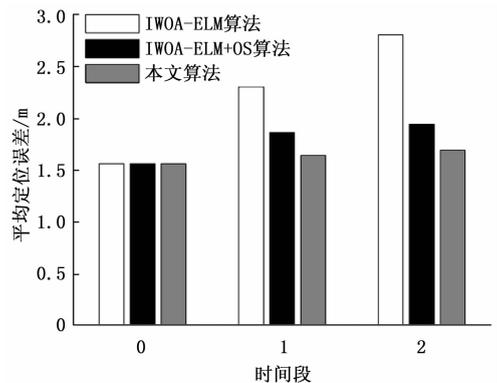


图 9 三种算法不同时间段定位误差变化

5 结束语

1) 引入多样性变异操作优化 WOA 算法, 优化后的 IWOA 算法全局寻优能力表现更好, 利用 IWOA 算法对 ELM 的输入权值和隐含层阈值进行优化, 提高了 ELM 神经网络的泛化能力。

2) 引入带动态权值因子的在线连续学习方法, 克服初始定位模型无法适应井下环境时变性的缺点, 能够根据在线阶段更新的动态校准数据实时调整定位模型。在环境发生变化后仍有较高的定位精度。

3) 对实验结果分析得出, 本文算法在环境未发生动态变化时的定位精度相比于 BP、ELM、WOA-ELM 算法更高。在环境发生动态变化之后, 通过本文提出的动态校准方案, 定位平均误差未发生较大变化, 定位稳定性最好。

4) 下一步工作将研究井下人员的移动模式, 根据人员移动模式的特点找到相邻时间点人员位置之间的关联, 对连续定位的结果进行修正。预计可以剔除一些误差较大的定位结果, 以此进一步提高定位精度。

参考文献:

- [1] 张立亚. 全矿井融合通信系统研究 [J]. 工矿自动化, 2018, 44 (3): 12-16.
- [2] LIU D, SHENG B, HOU F, et al. From Wireless Positioning to Mobile Positioning: An Overview of Recent Advances [J]. IEEE Systems Journal, 2014, 8 (4): 1249-1259.
- [3] 刘夏, 莫树培, 何惠玲, 等. 基于优化 RBF 神经网络的无线室内定位 [J]. 电讯技术, 2019, 59 (11): 1261-1267.
- [4] 崔丽珍, 许凡非, 王巧利, 等. 基于 PSO-BP 神经网络的煤矿井下自适应定位算法 [J]. 工矿自动化, 2018, 44 (2): 74-79.
- [5] GUAN Y, LIU T, HUANG G. ELM-based Hybrid Intrusion Detection Scheme in Wireless Sensor Network [J]. Computer Engineering, 2015, 41 (3): 136-141.
- [6] ALJARAH I, FARIS H, MIRJALILI S. Optimizing connection weights in neural networks using the whale optimization algorithm [J]. Soft Computing, 2018, 22 (1): 1-15.
- [7] ZOU H, ZHOU Y, JIANG H, et al. Adaptive Localization in Dynamic Indoor Environments by Transfer

- Kernel Learning [C] // 2017 IEEE Wireless Communications and Networking Conference (WCNC), 2017: 1-6.
- [8] HOANG M T, YUEN B, DONG X, et al. Recurrent Neural Networks for Accurate RSSI Indoor Localization [J]. IEEE Internet of Things Journal, 2019 (99): 1-1.
- [9] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: Theory and applications [J]. Neurocomputing, 2006, 70 (1/3): 489-501.
- [10] HUANG G B, ZHOU H, DING X, et al. Extreme Learning Machine for Regression and Multiclass Classification [J]. IEEE Transactions on Systems Man & Cybernetics Part B, 2012, 42 (2): 513-529.
- [11] Mirjalili, Seyedali, Lewis, et al. The Whale Optimization Algorithm [J]. Advances in engineering software, 2016, 95: 51-67.
- [12] 褚鼎立, 陈红, 王旭光. 基于自适应权重和模拟退火的鲸鱼优化算法 [J]. 电子学报, 2019, 47 (5): 992-999.
- [13] 王坚浩, 张亮, 史超, 等. 基于混沌搜索策略的鲸鱼优化算法 [J]. 控制与决策, 2019, 34 (9): 1893-1900.
- [14] 龙文, 蔡绍洪, 焦建军, 等. 求解大规模优化问题的改进鲸鱼优化算法 [J]. 系统工程理论与实践, 2017, 37 (11): 2983-2994.
- [15] YANG Z, ZHANG P, CHEN L. RFID-enabled indoor positioning method for a real-time manufacturing execution system using OS-ELM [J]. Neurocomputing, 2014, 174(JAN.22PT.A):121-133.
- [16] CAO W, MING Z, XU Z, et al. Online Sequential Extreme Learning Machine With Dynamic Forgetting Factor [J]. IEEE Access, 2019 (99): 1-1.
- [17] 姜启登. 基于位置指纹与惯性测量的室内定位技术研究 [D]. 天津: 天津大学, 2017.
- [18] 崔丽珍, 李丹阳, 王巧利, 等. 煤矿井下基于射线跟踪法的信道建模研究 [J]. 中国矿业, 2019, 28 (8): 94-98.
- [19] 朱顺涛. 室内位置指纹定位算法的研究 [D]. 无锡: 江南大学, 2018.
- [20] CHRYSIKOS T, GEORGOPOULOS G, KOTSOPOULOS S. Site-specific validation of ITU indoor path loss model at 2.4 GHz [C] // IEEE International Symposium on. IEEE, 2009: 1-6.