

改进麻雀算法在天波雷达定位中的应用

陈深^{1**}, 刘以安^{1*}, 宋海凌²

¹江南大学人工智能与计算机学院, 江苏 无锡 214122;

²海军研究院, 北京 100161

摘要 针对复杂战场环境要求天波雷达快速精准定位的问题,提出一种基于多策略改进麻雀搜索算法的定位模型。首先,使用立方混沌映射、步长因子动态调整、反向学习和混合变异算子对麻雀搜索算法进行改进,形成改进的麻雀搜索算法;然后,采用改进后的麻雀搜索算法寻找混合核极限学习机(HKELM)最优的核函数参数和混合核的权重系数;最后,使用寻优后的HKELM对天波雷达探测到的目标进行定位。结果表明,改进后的麻雀搜索算法在精度上和稳定性上优于用基本麻雀搜索算法改进的HKELM模型和极限学习机(ELM)定位模型,表明了所提算法的有效性。

关键词 光计算; 天波雷达; 目标定位; 麻雀搜索算法; 混合核极限学习机

中图分类号 TP391.9

文献标志码 A

DOI: 10.3788/LOP213363

Application of Improved Sparrow Algorithm in Sky-Wave Radar Location

Chen Shen^{1**}, Liu Yian^{1*}, Song Hailing²

¹School of Artificial Intelligence and Computer Science, Jiangnan University, Wuxi 214122, Jiangsu, China;

²Naval Research Institute, Beijing 100161, China

Abstract As complex battlefield environment requires rapid and accurate positioning of sky-wave radar, a positioning model based on multi-strategy improved sparrow search algorithm is proposed. First, cubic chaotic mapping, dynamic adjustment of step factor, reverse learning, and mixed mutation operator are used to invent an improved sparrow search algorithm. Then, the improved sparrow search algorithm is used to find the best-fit kernel function parameters and weight coefficient of mixed kernel of hybrid kernel extreme learning machine (HKELM). Finally, the optimized HKELM is used to locate the target detected by the skywave radar. The results show that the accuracy and stability of improved sparrow search algorithm are not only superior to the HKELM location model which is optimized by the basic sparrow search algorithm, but also stronger than the extreme learning machine (ELM) location model. In other words, the effectiveness of the method is proved.

Key words optics in computing; sky-wave radar; target location; sparrow search optimization algorithm; hybrid kernel extreme learning machine

1 引言

天波超视距雷达^[1]因其探测距离远、覆盖范围大、抗隐身能力强和单位面积所需成本低等优点,在战略预警、防空反导和反隐身等方面得到广泛的应用。因此,各个军事强国投入大量的人力物力发展和研制天波超视距雷达,如何提高天波雷达的定位精度,实现对视距范围外目标准确、快速定位成为研究热点。

分布式多基站联合定位^[2]是目前天波雷达常用的定位方法。该方法通过一个发射站和多个接收站在空

间内不同位置进行分布式组网形成一个探测系统,完成相应的目标探测任务。贺承杰^[3]提出一种“1发3收”的多站联合定位方法,但该方法需要优化布站几何构型,且当各站之间距离增大时,会有较高的定位误差。侯强^[4]针对接收站位置不确定导致的估计误差提出改进的泰勒级数估计方法,对误差矢量的代价函数通过泰勒级数展开的方式进行求解。但该方法假设测量误差和接收位置误差均为高斯分布,在实际场景中,测量噪声会受到各种因素的影响,因此提供的初始值精度不高时,算法收敛慢。李晓莎^[5]提出一种新的基

收稿日期: 2021-12-27; 修回日期: 2022-02-23; 录用日期: 2022-03-03; 网络首发日期: 2022-03-13

基金项目: 国家自然科学基金(61673193, 62076110)、江苏省自然科学基金(BK20181341)

通信作者: *Lya_wx@jiangnan.edu.cn; **1564844074@qq.com

于二次估计的时频差及侧向交叉的协同定位技术,该技术在目标位置进行第一次估计时使用无源侧向定位代替无源时差定位,但并未对复杂运动模式下目标的定位精度进行研究。宋萍等^[6]提出一种改进的蜻蜓优化算法,通过改进的蜻蜓算法寻找极限学习机(ELM)的最优权值和偏置,并通过改进后的 ELM 学习多基站天波雷达到达时间差(TDOA)和目标经纬度的关系实现对目标的位置预测。相较于传统定位算法,该算法虽然在精度上有了很大的提升,但蜻蜓算法寻优精度差且耗时长,依旧有较大的提升空间。

为了发挥分布式多基站联合定位与时差混合定位算法优势,结合混合核极限学习机(HKELM)较好的泛化性能,本文提出一种基于混合多策略改进麻雀算法(CACMSSA)优化的 HKELM 定位模型,利用 CACMSSA 对 HKELM 参数进行寻优,寻找 HKELM 最优参数组合,通过优化的 HKELM 网络实现天波雷达目标的预测,进一步提高天波超视距雷达定位的精度。

2 基本定位原理介绍

2.1 多基站 TDOA 联合定位原理

在分布式多基站联合定位系统中,通过主站发射电磁波和接收站接收到目标反射回电磁波的时间差对目标进行定位。系统中的主站在发射电磁波的同时,也接收探测目标反射回来的回波,各个子接收站与主站分开放置在不同位置,接收来自同一被探测目标反射回来的电磁波。多基地联合定位系统平面图如图 1 所示, T 为主站,对需要探测的区域发射电磁波,被探测到的目标反射回来的电磁波被子接收站 R_1 、 R_2 、 R_3 接收到。其中,主站需要 R_1 、 R_2 、 R_3 中至少两个一起组成联合定位系统。

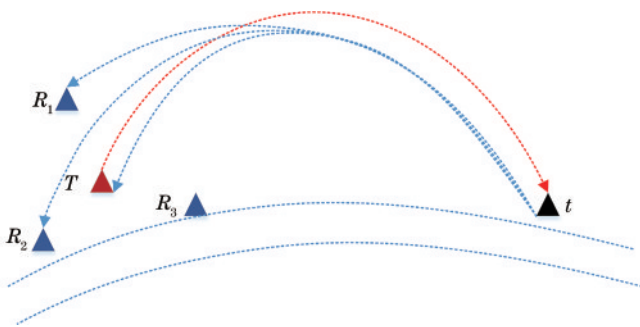


图 1 多基地定位模型

Fig. 1 Multi-static location model

2.2 基于 HKELM 的 TDOA 定位模型

宋萍等^[6]将多基地联合定位系统中的各个子接收站与发射站的 TDOA 信息作为 ELM 输入参数进行拟合,实现对探测区域内被探测到的目标位置的预测。在 HKELM 定位模型中,主发射站和各个子接收站的 TDOA 信息作为 HKELM 的输入层参数。假设主发

射站 T 在 t_0 时刻发射探测信号,对目标区域进行扫描探测,各个子接收站接收到目标回波的时间分别是 t_1 、 t_2 、 t_3 ,所以 HKELM 输入层输入向量 \mathbf{V} 为

$$\mathbf{V} = (\nabla t_{10}, \nabla t_{20}, \nabla t_{30}), \quad (1)$$

式中: ∇t_{i0} 表示第 i 个接收站收到目标回波的时间 t_i 与主发射站 T 发射探测时间 t_0 的差值, $i = 1, 2, 3$ 。

以被探测目标的经纬度作为 HKELM 的输出向量, HKELM 的输出向量 \mathbf{O} 为

$$\mathbf{O} = (B_A, L_A), \quad (2)$$

式中: B_A 表示纬度; L_A 表示经度。

3 改进麻雀算法优化极限学习机的定位模型

3.1 麻雀算法的改进

麻雀在觅食过程中种群分为两种:发现者和加入者。Xue 等^[7]根据麻雀这一种群觅食行为提出麻雀搜索算法(SSA)。虽然 SSA 有比较好的寻优性能,能快速求解问题,但是也存在早熟现象和寻优精度不高的缺点,本研究对 SSA 存在的问题进行优化,提出一种混合多策略改进的麻雀搜索算法。

3.1.1 立方混沌映射初始化种群

与其他群智能算法一样,原始 SSA 在求解复杂问题时,通过随机生成位置的方法初始化麻雀种群的个体位置,会导致种群的多样性低,对问题进行寻优的收敛速度比较慢。为了能够让麻雀个体在算法开始时有较高的全局搜索能力,需要让麻雀种群的位置均匀分布在整个问题的解空间内,因此使用混沌算子对麻雀种群进行初始化。不同于 Logistics 混沌映射产生的两端高中间低的不均匀变量,立方混沌映射^[8]产生的变量更加均匀。使用下式产生立方混沌映射:

$$y_{n+1} = 4y_n^3 - 3y_n, \quad (3)$$

式中: $-1 < y_n < 1, n = 0, 1, \dots, n$ 。在实际应用时,当 $y_0 \neq 0$ 时,混沌就会发生。

按照式(4)对麻雀个体每一维使用立方混沌映射。

$$X_{i,j} = X_{lb,j} + (X_{ub,j} - X_{lb,j}) \times (y_i + 1) / 2, \quad (4)$$

式中: $X_{i,j}$ 为第 i 个麻雀个体在第 j 维的位置; $X_{ub,j}$ 和 $X_{lb,j}$ 为每个个体在第 j 维的上下边界。通过立方混沌映射过后的麻雀个体的位置在问题的解空间内分布更加均匀。

3.1.2 步长因子动态调整

在 SSA 中,发现者位置更新的步长参数为随机数,无法满足算法在问题的解空间的有效搜索,导致 SSA 会陷入局部最优。本研究借鉴粒子群算法中惯性权重的思想,较大的惯性权重有利于粒子进行全局搜索,较小的惯性权重有利于粒子进行局部搜索。因此对发现者步长因子进行动态调整,可以提高算法的全局搜索能力与局部开发能力。对步长控制参数 ω 的改进如下:

$$\omega = (f_g - f_w) \cdot \exp \left[-20 \cdot \tan \left(\frac{t}{N_{\text{Max_iter}}} \right)^2 \right], \quad (5)$$

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t + \omega (X_{\text{best}}^t - X_{i,j}^t) Q_{\text{rand}}, & R_2 < T_s \\ X_{i,j}^t + Q, & R_2 \geq T_s \end{cases}, \quad (6)$$

式中: f_g 是当代所有个体对应的最佳适应度值; f_w 是当代所有个体对应的最差适应度值; $N_{\text{Max_iter}}$ 为最大迭代次数; X_{best}^t 表示第 t 代的最优麻雀的位置; Q_{rand} 为随机数; Q 为服从标准正态分布的随机数; R_2 和 T_s 分别表示预警值和安全值。从式(5)可以看出, ω 在迭代前期有较大的值, 有利于引导麻雀种群在更大范围内搜索, 在迭代后期的值较小, 有利于增强麻雀种群在局部搜索的能力。式(6)为改进后的发现者位置更新方式。

3.1.3 反向学习策略

许多群体智能算法都采用随机算子对最优解进行扰动, 这将导致收敛速度变慢。2005年, Tizhoosh^[9] 提出反向学习策略(OBL)。OBL提出对点的概念, 用对立代替随机, 在当前问题的解空间内寻找当前解的反向解, 然后通过评估当前解和反向解的值, 保留更好的解来取代原解中较差的解。SSA中, 作为发现者的麻雀个体拥有较好的适应度值, 因此, 只对麻雀种群个体中的发现者生成反向解。利用OBL生成麻雀种群中发现者的反向解的描述如下:

设 $X_i^t = [X_{i,1}^t, X_{i,2}^t, \dots, X_{i,N}^t]$ 是问题第 t 代的一个可行解, $X_{i,j}^t$ 是第 i 只麻雀个体在第 j 维的元素值, $X_{i,j}^{t'}$ 是 $X_{i,j}^t$ 对应的反向解。 $X_{i,j}^{t'}$ 的表达式为

$$X_{i,j}^{t'} = c_{\text{ub},j} + c_{\text{lb},j} - X_{i,j}^t, \quad (7)$$

式中: $c_{\text{ub},j}$ 和 $c_{\text{lb},j}$ 分别是当前第 t 次迭代时麻雀个体的第 j 维的上界和下界, $i \in [1, D]$, D 是发现者个体数量, $j \in [1, N]$, N 是可行解的空间维数。

3.1.4 混合变异算子

OBL策略虽然使麻雀算法收敛速度加快, 但OBL策略无法帮助算法跳出局部最优, 因此在SSA中最优麻雀个体的位置引入变异操作, 通过对最优麻雀个体进行变异操作产生新的麻雀个体来扩大麻雀种群的搜索范围, 在变异操作后, 新个体可以有效带领其他个体跳出局部最优。赵青杰等^[10-11] 使用改进柯西变异的方法避免算法陷入局部最优。李永恒等^[12] 使用改进的高斯变异的方法提高算法后期的局部搜索能力。本研究通过权重系数将高斯变异和柯西变异结合形成高斯-柯西混合变异算子, 在迭代过程中对高斯变异和柯西变异的权重不断调整, 发挥高斯变异和柯西变异的优势。

使用标准的柯西分布进行变异处理, 可以帮助变异之后的麻雀个体迅速跳出局部极值。按照式(8)对当前最优麻雀个体进行变异:

$$X_{\text{best},c}^{t'} = X_{\text{best}}^t + X_{\text{best}}^t \text{Cauchy}(0, 1), \quad (8)$$

式中: $X_{\text{best},c}^{t'}$ 表示经过标准柯西分布变异之后麻雀个体的位置。

高斯分布的点分布较为集中, 该特征能够产生于原点相距较近的随机数, 经过高斯变异之后的麻雀个体在最优位置进行很小的范围内扰动, 可以提高变异个体的局部搜索能力。使用标准的高斯分布进行变异处理, 按照式(9)对当前最优麻雀个体进行变异:

$$X_{\text{best},g}^{t'} = X_{\text{best}}^t + X_{\text{best}}^t \text{Gaussian}(0, 1), \quad (9)$$

式中: $X_{\text{best},g}^{t'}$ 表示经过标准高斯分布变异之后麻雀个体的位置。

高斯-柯西混合变异算子通过线性权重系数将标准高斯变异得到的新麻雀个体位置 $X_{\text{best},g}^{t'}$ 和标准柯西变异得到的新麻雀个体位置 $X_{\text{best},c}^{t'}$ 生成一个全新的麻雀个体位置 $X_{\text{best,new}}^{t'}$ 。新麻雀个体 $X_{\text{best,new}}^{t'}$ 的表达式为

$$X_{\text{best,new}}^{t'} = \frac{t}{N_{\text{Max_iter}}} X_{\text{best},g}^{t'} + \left(1 - \frac{t}{N_{\text{Max_iter}}} \right) X_{\text{best},c}^{t'}. \quad (10)$$

从式(10)可以看出, 算法开始运行时, t 值较小, 柯西变异的权值较大, 通过柯西变异获得较大步长, 避免算法陷入局部最优解。随着算法不断运行, t 值较大, 高斯变异的权值较大, 高斯变异杰出的局部搜索能力使得候选解在局部范围进行精确搜索, 提高算法的寻优精度。

经过高斯-柯西混合变异算子产生的解, 由Metropolis准则决定接受与否。

$$P_m = \begin{cases} 1, & f_{\text{new}} \leq f_g \\ \exp \left(-\frac{f_{\text{new}} - f_g}{T_e} \right), & f_{\text{new}} > f_g \end{cases}, \quad (11)$$

式中: T_e 为当前温度; f_{new} 表示变异之后的解。

在对最优麻雀个体的位置进行扰动变异更新后产生的最新麻雀个体, 计算两个麻雀个体位置的适应度值, 通过适应度值使用式(11)计算 P_m 。比较 P_m 与随机数 Q_{rand} 的大小, 若随机数 Q_{rand} 大于 P_m , 放弃新麻雀的位置, 否则接受新麻雀的位置。算法在选择最优值的同时, 保留潜力觅食位置。

3.2 CACMSSA-HKELM 目标定位建模

核极限学习机(KELM)是Huang^[13] 在传统的ELM网络的基础上改进而来的网络。KELM在ELM中引入核函数, 通过核函数完成样本在高维特征空间的映射, 在高维空间将特征区分开, 因此KELM不需要知道隐含层节点数就可以输出预测结果。相较于ELM使用随机矩阵进行初始化, KELM使用的核矩阵有更好的泛化性能和稳定性。

HKELM在ELM中引入混合核函数^[14], 通过混合核矩阵代替ELM的随机矩阵。混合核函数是通过权重系数将两个不同的核函数结合形成的, 混合后的核函数可以兼具不同核函数的优点, 使得多核的HKELM比单核的KELM泛化性更好。本研究采用两个经典核函数构造混合核函数, 混合核函数 $K_{\text{hk}}(x, x_j)$ 的表达式为

$$K_{\text{hk}}(x, x_j) = \lambda K_{\text{poly}}(x, x_j) + (1 - \lambda) K_{\text{rbf}}(x, x_j), \quad (12)$$

式中： λ 表示权重系数， $\lambda \in [0, 1]$ ； $K_{\text{rbf}}(x, x_j)$ 表示径向基核函数(RBF)； $K_{\text{poly}}(x, x_j)$ 表示 Poly 核函数。

KELM 对参数选择敏感，参数选择对模型预测结果有很大的影响。因此在 HKELM 中，需要对权重系数 λ 、惩罚参数 C 、RBF 中的核参数 γ 和 Poly 中的核参

数 d 构成的参数组 (λ, C, γ, d) 进行寻优。相较于传统 SSA，CACMSSA 有较好的寻优效果，采用 CACMSSA 寻找 HKELM 参数组 (λ, C, γ, d) 的最优参数组合，将优化后的 HKELM 网络应用到天波超视距雷达中，实现对目标的定位。模型流程图如图 2 所示：

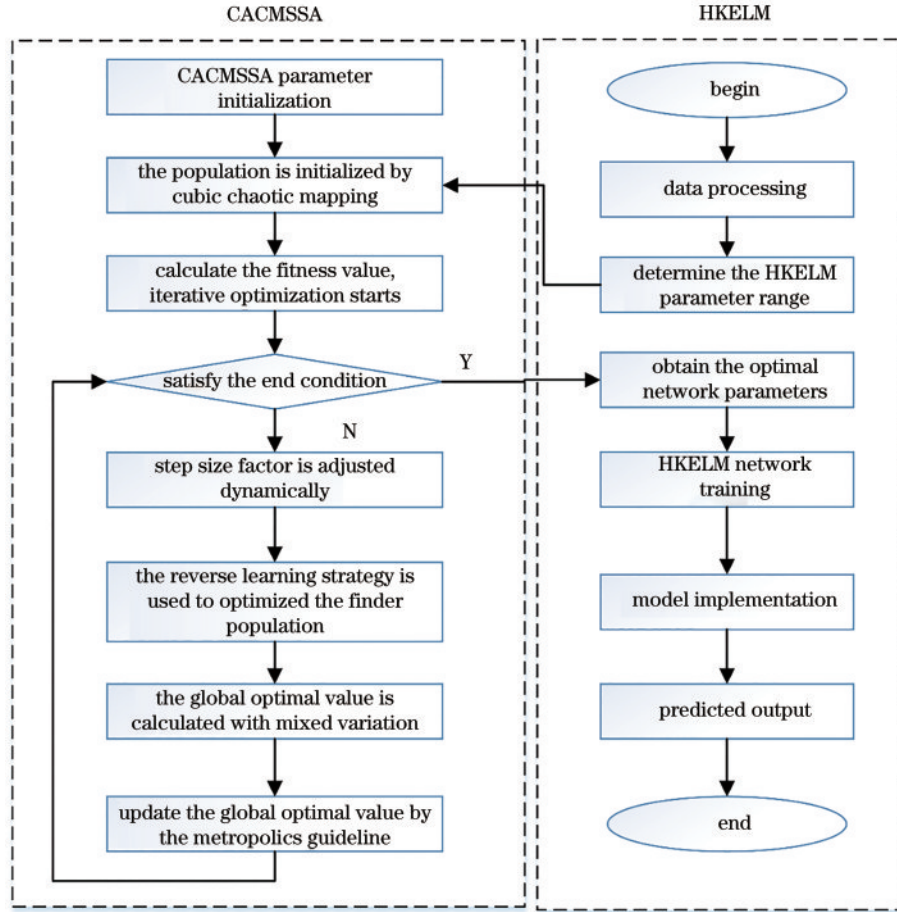


图 2 CACMSSA-ELM 定位模型流程图

Fig. 2 CACMSSA-ELM location model flow chat

为了评估算法的寻优性能，采用式(13)作为适应度评价函数：

$$f = m \times \left(\sum_{i=1}^M |P_i^* - P_i| \right), \quad (13)$$

式中： M 为输入训练样本的总数目； P_i^* 为模型对输入目标预测的位置； P_i 为真实输入的目标位置； m 为不为零的常数。

4 仿真与性能分析

4.1 算法性能优化测试

4.1.1 参数设置

选取较新的群智能优化算法——蜻蜓算法(DA)^[15]、灰狼算法(GWO)^[16]、SSA^[7]、毛清华等^[17]提出的改进麻雀算法(ISSA)和所提 CACMSSA 进行对比。以上 5 种算法的种群规模均设置为 10，需要求解的问题维度设置为 30，算法的迭代次数为 300，5 种算法的基本

参数一致。

4.1.2 算法性能结果对比分析

为检验所提 CACMSSA 的效果，选取 4 个维度为 30 的典型测试函数，包括 2 个单峰函数 (f_1, f_2) 和 2 个多峰函数 (f_3, f_4)，使用以上 5 种算法对 4 个不同的函数进行对比测试，4 个函数的具体信息如表 1 所示。

4 个基准函数的测试结果如表 2 表示。从表 1 可

表 1 基准测试函数

Table 1 Benchmark function

| Function | Function name | Dimension | Search scope | Optimal value |
|----------|---------------|-----------|-----------------|---------------|
| f_1 | Sphere | 30 | $[-100, 100]$ | 0 |
| f_2 | Schwefel 2.22 | 30 | $[-10, 10]$ | 0 |
| f_3 | Rastrigin | 30 | $[-5.12, 5.12]$ | 0 |
| f_4 | Ackley | 30 | $[-32, 32]$ | 0 |

表 2 改进 SSA 的仿真结果
Table 2 Simulation results of improved SSA

| Function | Algorithm | Optimal value | Worst value | Average value | Standard deviation |
|----------|-----------|---------------------------|--------------------------|--------------------------|--------------------------|
| f_1 | DA | 0.0032 | 873.2685 | 169.777 | 226.3133 |
| | GWO | 1.1338×10^{-9} | 2.2480×10^{-16} | 2.5185×10^{-17} | 5.5118×10^{-17} |
| | SSA | 5.3392×10^{-113} | 4.2810×10^{-10} | 4.8375×10^{-11} | 1.1872×10^{-10} |
| | ISSA | 1.6590×10^{-19} | 5.0929×10^{-12} | 3.5981×10^{-13} | 1.2056×10^{-12} |
| | CACMSSA | 4.2356×10^{-112} | 1.9696×10^{-42} | 9.8482×10^{-44} | 4.4042×10^{-43} |
| f_2 | DA | 1.2641 | 34.8134 | 8.3417 | 8.2309 |
| | GWO | 6.6862×10^{-12} | 5.6068×10^{-10} | 8.7514×10^{-11} | 1.2369×10^{-10} |
| | SSA | 3.8350×10^{-281} | 5.5796×10^{-5} | 3.2048×10^{-6} | 1.2482×10^{-5} |
| | ISSA | 3.4242×10^{-15} | 1.2965×10^{-6} | 1.0399×10^{-7} | 2.8982×10^{-7} |
| | CACMSSA | 5.3089×10^{-46} | 2.4327×10^{-20} | 1.4225×10^{-21} | 5.4119×10^{-21} |
| f_3 | DA | 69.3874 | 283.9612 | 181.3864 | 58.2389 |
| | GWO | 6.194 | 40.1776 | 16.2064 | 7.2727 |
| | SSA | 0 | 2.2072×10^{-6} | 1.2850×10^{-7} | 4.9306×10^{-7} |
| | ISSA | 0 | 1.0406×10^{-9} | 1.1010×10^{-10} | 2.9733×10^{-10} |
| | CACMSSA | 0 | 0 | 0 | 0 |
| f_4 | DA | 8.9344 | 20.2145 | 15.834 | 3.6235 |
| | GWO | 1.4055×10^{-5} | 1.0287×10^{-3} | 5.1042×10^{-5} | 3.0064×10^{-5} |
| | SSA | 8.8818×10^{-16} | 8.5112×10^{-5} | 4.3437×10^{-6} | 1.9013×10^{-5} |
| | ISSA | 1.1102×10^{-13} | 3.3480×10^{-7} | 5.2499×10^{-8} | 1.0168×10^{-7} |
| | CACMSSA | 8.8818×10^{-16} | 8.8818×10^{-16} | 8.8818×10^{-16} | 0 |

可以看出,4个基准函数的最优值均为0。与DA、GWO、SSA和ISSA相比,CACMSSA在30次实验中的平均值都是最接近基准函数的最优值的,即CACMSSA有较好的寻优效果。在对函数 f_3 的寻优过程中,CACMSSA每次都找到了函数的全局最优值。从5种算法的方差来看,CACMSSA的方差在5种算法中是最小的,说明CACMSSA在求解问题时比较稳定。这是因为CACMSSA在初始化时使用立方混沌映射,使得种群有较好的混沌性,通过动态权值优化提高算法的收敛速度,同时,通过对麻雀种群中的发现者使用反向学习策略,提高算法的搜索能力,最后使用高斯-柯西混合变异算子策略,变异后的麻雀个体更容易逃出局部极值。Metropolis准则使算法在选择最优值的同时保留潜力觅食位置。

图3是5种算法在单峰函数的收敛曲线图,图3(a)是5种算法在单峰函数 f_1 的收敛曲线图,图3(b)是5种算法在单峰函数 f_2 的收敛曲线图。从图3(a)可以看出,CACMSSA达到的精度最接近问题的最优解,从图3(b)可以看出,CACMSSA较快接近问题的最优解,ISSA并未表现出较好的寻优效果。

图4是5种算法在多峰函数上的收敛曲线图,图4(a)是5种算法在多峰函数 f_3 上的收敛曲线图,图4(b)是5种算法在多峰函数 f_4 上的收敛曲线图。从图4(a)可以看出,CACMSSA和ISSA在 f_3 函数上都达到了最优值,在达到最优值的情况下,CACMSSA比ISSA迭代次数更少。从图4(b)可以看出,CACMSSA在多峰函数 f_4 上对问题解的精度明显高

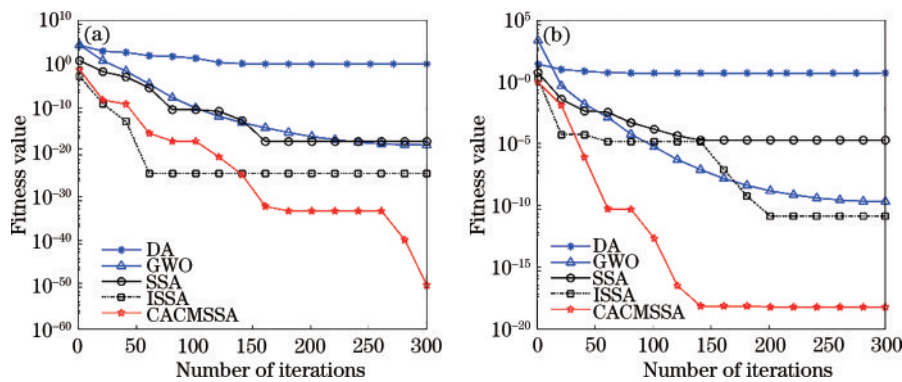


图 3 单峰函数收敛曲线图。(a) f_1 收敛曲线图;(b) f_2 收敛曲线图

Fig. 3 Convergence curves of unimodal function. (a) Convergence curve of f_1 ; (b) convergence curve of f_2

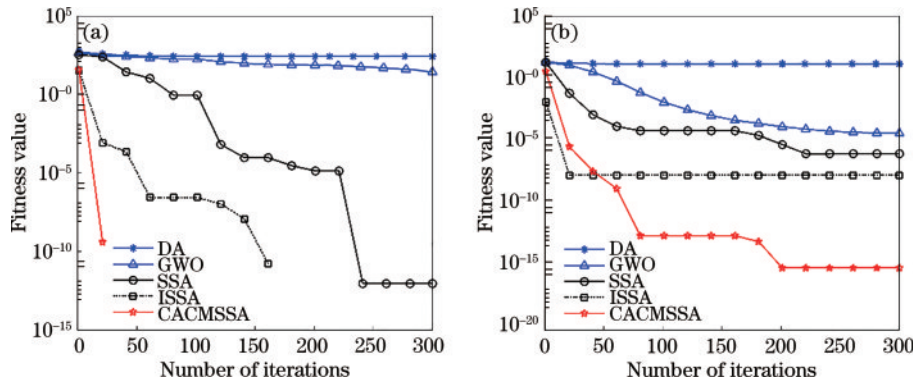


图 4 多峰函数收敛曲线图。(a) f_3 收敛曲线图; (b) f_4 收敛曲线图

Fig. 4 Convergence curves of multimodal function. (a) Convergence curve of f_3 ; (b) convergence curve of f_4

于其他 4 种算法。在多峰函数上, CACMSSA 表现出来的优势比在单峰函数上更加明显。

综上所述, 5 种算法在基本参数相同的情况下, 无论是在单峰函数 f_1 、 f_2 上, 还是在多峰函数 f_3 、 f_4 上, CACMSSA 都表现出来较好的寻优能力和稳定性。

4.2 定位模型验证

在两种网络 ELM 和 KELM 中分别建立基于 CACMSSA 的定位模型, 通过两组对比实验验证 CACMSSA-HKELM 定位模型的效果。在第 1 组实验中, 分别建立 ELM 定位模型、SSA-ELM 定位模型、CACMSSA-ELM 定位模型和文献 [6] 提出的 LACMODA-ELM 定位模型。在第 2 组实验中, 分别建立 CACMSSA-KELM 定位模型、SSA-HKELM 定位模型和 CACMSSA-HKELM 定位模型。通过不同定位模型的预测误差精度来验证各自定位的效果, 为了评估各个定位模型的效果, 采用平均绝对百分比误差 (M_{APE}) 来描述模型预测的偏离程度, 平均绝对误差 (M_{AE}) 来评价各个模型的预测的精确度。

$$M_{APE} = \frac{1}{N_T} \sum_{n=1}^{N_T} \left| \frac{P_n - P_n^*}{P_n} \right|, \quad (14)$$

$$M_{AE} = \frac{1}{N_T} \sum_{n=1}^{N_T} |P_n - P_n^*|, \quad (15)$$

式中: N_T 为测试样本总数。 M_{AE} 越小, 算法的预测精度越高。

在对比实验部分, 采集 300 组 TDOA 数据, 按照 13:2 的比例将采集到的 TDOA 数据分为训练集和测试集。在第 1 组对比实验中, 将归一化以后的数据输入 ELM、SSA-ELM、LACMODA-ELM 和 CACMSSA-ELM 定位模型中, 3 种智能优化算法的种群规模设置为 30, 最大迭代次数设置为 200, 解向量的搜索空间设置为 $[-1, 1]$, LACMODA-ELM 定位模型中, 反向种群概率 j_i 设为 0.5, CACMSSA-ELM 定位模型中, 温度 T_e 为 300。在第 2 组实验中, 将处理好的数据分别输入 CACMSSA-KELM、SSA-HKELM 和 CACMSSA-HKELM 定位模型中, 2 种智能优化算法的种群规模设置为 5, 最大迭代次数设置为 50, 其他与第 1 组对比实验中的参数相同, CACMSSA-KELM 定位模型中, 核函数采用 RBF。采用上述 7 种定位模型进行对比实验。

图 5 表示 CACMSSA 优化的两种网络定位模型对测试集 40 个目标位置的预测情况, 横轴表示经度,

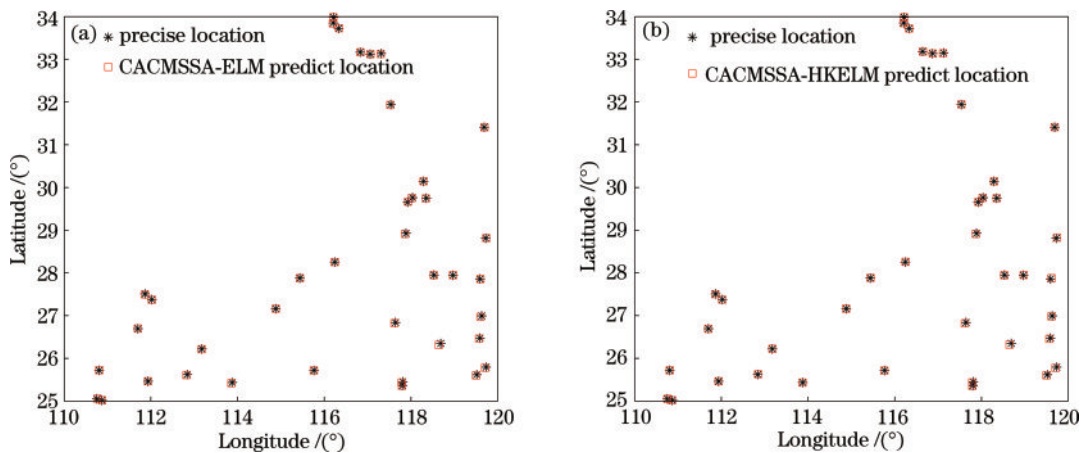


图 5 目标位置预测。(a) CACMSSA-ELM 目标位置预测; (b) CACMSSA-HKELM 目标位置预测

Fig. 5 Target prediction position. (a) Target prediction position of CACMSSA-ELM; (b) target prediction position of CACMSSA-HKELM

纵轴表示纬度,图 5(a)表示 CACMSSA-ELM 定位模型对测试集 40 个目标位置的预测情况,图 5(b)表示 CACMSSA-HKELM 定位模型对测试集 40 个目标位置的预测情况。从图 5(a)可以看出,CACMSSA-ELM 预测的目标的经纬度和实际目标的经纬误差较小,每个点的位置与真实值都很接近。从图 5(b)可以看出,CACMSSA-HKELM 预测目标的经纬度和实际目标经纬度贴合程度更高。

图 6 表示不同定位模型对目标预测经纬度的误差对比图,图 6(a)表示 ELM 模型对目标预测经纬度误差对比图,图 6(b)表示 KELM 模型对目标预测经纬度误差对比图,图 6(a)表示 ELM 模型对目标预测经纬度误差对比图,图 6(b)表示 KELM 模型对目标预测经纬度误差对比图。




图 6 目标预测经纬度误差。(a)ELM 模型目标预测经纬度误差;(b)KELM 模型目标预测经纬度误差

Fig. 6 Latitude and longitude error of target predict. (a) Latitude and longitude error of ELM model target predict; (b) latitude and longitude error of KELM model target predict

表 3 表示 7 种不同的 ELM 定位模型方法的误差。比较方法 2、3、4 和方法 1 可以看出:使用群智能优化算法优化的 ELM 定位模型精度高于未优化的 ELM 定位模型;方法 4 和方法 2 相比较,CACMSSA-ELM 定位模型在平均绝对百分比误差和平均绝对误差上小于 SSA-ELM 定位模型,说明 CACMSSA-ELM 定位模型预测的效果好于 SSA-ELM 定位模型预测的效果。比较方法 4 和方法 3 可以看出,CACMSSA-ELM 定位模型预测效果好于 LACMODA-ELM 定位模型。比较方法 4 和方法 5 可以看出,两种定位模型误差相差不大,CACMSSA-KELM 定位模型耗时更短。比较方法 7 和方法 5 可以看出,基于混合核函数的核极限学习

机定位模型的精度高于单核的核极限学习机。比较方法 7 和方法 6 可以看出,改进麻雀算法的 CACMSSA-HKELM 定位模型优于麻雀算法的 SSA-HKELM 定位模型。从时间性能上对几种定位模型进行分析,表 3 中各定位模型达到表中的定位误差时,LACMODA-ELM 定位模型训练平均耗时 49.9527 s,SSA-HKELM 定位模型训练平均耗时 3.1301 s,CACMSSA-HKELM 定位模型训练平均耗时 3.6380 s。与 LACMODA-ELM 定位模型相比,CACMSSA-HKELM 和 SSA-HKELM 定位模型的 M_{APE} 分别减少 27.71% 和 9.64%。这说明改进的 CACMSSA-HKELM 定位模型是快速、高精度的。

表 3 7 种不同 ELM 预测方法的误差

Table 3 Error of seven ELM prediction methods

| No. | Method | $M_{AE} / (^\circ)$ | $M_{APE} / (^\circ)$ |
|-----|------------------------------|---------------------|----------------------|
| 1 | ELM location model | 0.1064 | 0.0429 |
| 2 | SSA-ELM location model | 0.0224 | 0.0094 |
| 3 | LACMODA-ELM location model | 0.0200 | 0.0083 |
| 4 | CACMSSA-ELM location model | 0.0183 | 0.0073 |
| 5 | CACMSSA-KELM location model | 0.0180 | 0.0072 |
| 6 | SSA-HKELM location model | 0.0189 | 0.0075 |
| 7 | CACMSSA-HKELM location model | 0.0145 | 0.0060 |

5 结 论

针对传统天波超视距雷达定位方法中存在的定位精度差问题,提出一种基于多策略改进的 CACMSSA。将 CACMSSA 用于 HKELM 的优化,寻找 HKELM 的最优参数组合,将优化后的 HKELM 用于对多基地天波雷达对目标进行定位。实验结果表明,CACMSSA 在对多维问题进行寻优时,表现出较好的全局寻优性能和寻优速度。通过 CACMSSA 优化后的 HKELM 在天波雷达的定位应用中,对目标的

预测精度高于其他 ELM 定位模型和 KELM 定位模型,即改进的 CACMSSA-HKELM 是可行的。

参 考 文 献

- [1] 周万幸. 天波超视距雷达发展综述[J]. 电子学报, 2011, 39(6): 1373-1378.
Zhou W X. An overview on development of skywave over-the-horizon radar[J]. Acta Electronica Sinica, 2011, 39(6): 1373-1378.
- [2] 严韬, 陈建文, 罗欢, 等. 新体制天波超视距雷达技术述评[J]. 飞航导弹, 2015(3): 71-76.
Yan T, Chen J W, Luo H, et al. Review of new system sky wave over-the-horizon radar technology[J]. Aerodynamic Missile Journal, 2015(3): 71-76.
- [3] 贺承杰. 天波超视距雷达海面目标定位方法研究[J]. 雷达科学与技术, 2020, 18(5): 568-572, 578.
He C J. Surface target location method of sky wave over-the-horizon radar[J]. Radar Science and Technology, 2020, 18(5): 568-572, 578.
- [4] 侯强. 基于 TDOA 和 FDOA 的多站无源定位关键技术研究[D]. 济南: 山东大学, 2021.
Hou Q. Research on key technologies of multi-station passive localization based on TDOA and FDOA[D]. Jinan: Shandong University, 2021.
- [5] 李晓莎. 基于时频差及测向的协同定位跟踪技术研究[D]. 成都: 西南交通大学, 2017.
Li X S. Collaborative location and tracking technology based on TDOA/FDOA/AOA[D]. Chengdu: Southwest Jiaotong University, 2017.
- [6] 宋萍, 刘以安. 基于改进蜻蜓算法的多基地天波雷达定位模型[J]. 激光与光电子学进展, 2018, 55(11): 112001.
Song P, Liu Y A. Multi-static sky-wave over-the-horizon radar location model based on improved dragonfly algorithm[J]. Laser & Optoelectronics Progress, 2018, 55(11): 112001.
- [7] Xue J K, Shen B. A novel swarm intelligence optimization approach: sparrow search algorithm[J]. Systems Science & Control Engineering, 2020, 8(1): 22-34.
- [8] 汤安迪, 韩统, 徐登武, 等. 基于混沌麻雀搜索算法的无人机航迹规划方法[J]. 计算机应用, 2021, 41(7): 2128-2136.
Tang A D, Han T, Xu D W, et al. Path planning method of unmanned aerial vehicle based on chaos sparrow search algorithm[J]. Journal of Computer Applications, 2021, 41(7): 2128-2136.
- [9] Tizhoosh H R. Opposition-based learning: a new scheme for machine intelligence[C]//International Conference on Computational Intelligence for Modelling, Control and Automation and International Conference on Intelligent Agents, Web Technologies and Internet Commerce (CIMCA-IAWTIC'06), November 28-30, 2005, Vienna, Austria. New York: IEEE Press, 2005: 695-701.
- [10] 赵青杰, 李捷, 于俊洋, 等. 基于动态自适应权重和柯西变异的蝙蝠优化算法[J]. 计算机科学, 2019, 46(S1): 89-92.
Zhao Q J, Li J, Yu J Y, et al. Bat optimization algorithm based on dynamically adaptive weight and Cauchy mutation[J]. Computer Science, 2019, 46(S1): 89-92.
- [11] Moharam M H, Gouda M, Hennawy H M E. Hybrid clipping-PTS using enhanced PSO with Cauchy mutation to reduce PAPR of FBMC 5G systems[J]. International Journal of Systems, Control and Communications, 2019, 10(2): 147.
- [12] 李永恒, 赵志刚. 基于越界重置和高斯变异的蝙蝠优化算法[J]. 计算机工程与科学, 2019, 41(1): 144-152.
Li Y H, Zhao Z G. An improved bat algorithm based on cross-border relocation and Gaussian mutation[J]. Computer Engineering & Science, 2019, 41(1): 144-152.
- [13] Huang G B. An insight into extreme learning machines: random neurons, random features and kernels[J]. Cognitive Computation, 2014, 6(3): 376-390.
- [14] 张婷慧, 宇洁, 叶张林, 等. 结合粒子群寻优的混合核函数极限学习机分类模型[J]. 测绘科学技术学报, 2019, 36(1): 56-61.
Zhang T H, Yu J, Ye Z L, et al. Classification model research of mixed kernel extreme learning machine based on particle swarm optimization[J]. Journal of Geomatics Science and Technology, 2019, 36(1): 56-61.
- [15] Mirjalili S. Dragonfly algorithm: a new meta-heuristic optimization technique for solving single-objective, discrete, and multi-objective problems[J]. Neural Computing and Applications, 2016, 27(4): 1053-1073.
- [16] Mirjalili S, Mirjalili S M, Lewis A. Grey wolf optimizer[J]. Advances in Engineering Software, 2014, 69: 46-61.
- [17] 毛清华, 张强. 融合柯西变异和反向学习的改进麻雀算法[J]. 计算机科学与探索, 2021, 15(6): 1155-1164.
Mao Q H, Zhang Q. Improved sparrow algorithm combining Cauchy mutation and opposition-based learning[J]. Journal of Frontiers of Computer Science and Technology, 2021, 15(6): 1155-1164.