

基于改进灰狼算法的天波雷达定位模型

宋萍, 刘以安*

江南大学物联网工程学院, 江苏 无锡 214122

摘要 针对天波雷达方位分辨力低和传统解析算法定位误差较大的缺点, 提出一种混沌变异灰狼算法优化核极限学习机(KELM)的定位模型。首先, 该模型将分段线性混沌映射、自适应柯西变异和收敛因子的非线性化引入灰狼算法从而形成一种改进的灰狼算法; 然后, 采用改进后的灰狼算法对 KELM 的惩罚系数和核参数进行优化; 最后, 将优化后的 KELM 应用于天波雷达定位, 使建立的 KELM 定位模型具有更高的预测精度和更强的泛化能力。实验结果显示, 所提模型的预测结果与目标实测值基本一致, 预测精度高于标准灰狼优化算法改进的 KELM 模型和解析法定位模型, 为天波雷达定位提供了一种新的目标定位方法。

关键词 光计算; 天波雷达; 定位; 核极限学习机; 灰狼优化算法; 参数优化

中图分类号 TP391.9

文献标识码 A

doi: 10.3788/LOP56.032001

Sky-Wave Radar Location Model Based on Improved Grey Wolf Optimization Algorithm

Song Ping, Liu Yian*

College of IOT Engineering, Jiangnan University, Wuxi, Jiangsu 214122, China

Abstract Aimed at the disadvantages of the lower azimuth resolution of the sky-wave radar and larger position error of traditional analytic algorithm, a new locating model using chaotic mutation grey wolf optimization algorithm to optimize the kernel extreme learning machine (KELM) is put forward. First, the piecewise linear chaotic map, adaptive Cauchy mutation strategy and non-linearity of the convergence factor are introduced into the grey wolf optimization algorithm to form an improved grey wolf algorithm. Then, the improved grey wolf optimization algorithm is used to optimize penalty coefficient and kernel parameter of the KELM. Finally, the optimized the KELM is applied to sky-wave radar location, making the established KELM model have the high steady-state prediction accuracy and generalization performance. The experimental results show that the predicted results of the proposed model are basically consistent with the measured values, and the prediction accuracy is higher than that of the KELM location model, which is optimized by the standard grey wolf algorithm. A new target location method is provided for sky-wave radar.

Key words optics in computing; sky-wave radar; location; kernel extreme learning machine; grey wolf optimization algorithm; parameter optimization

OCIS codes 200.4260; 080.1753; 290.1350

1 引言

高频天波雷达^[1]利用电离层对高频探测电波的反射实现超远距离目标的探测, 具有探测距离远、覆盖范围大、反隐身能力强、预警时间长等战术特点。天波超视距雷达(OTHR)的检测和定位技术广泛

应用于远程预警与战术警戒、探测隐身飞机、核爆炸监测和维护海洋主权等方面, 其定位精度的提升是目前军事强国的研究热点。

目前天波雷达常用的定位方法主要包括测向定位、时差定位以及测向与时差混合定位。时差定位可以获得比较高的定位精度, 但是对各个接收站之

收稿日期: 2018-06-15; 修回日期: 2018-08-12; 录用日期: 2018-08-17

基金项目: 国家自然科学基金(61170120)

* E-mail: Lya_wx@jiangnan.edu.cn

间的时间同步要求比较苛刻,导致系统比较复杂。宋君等^[2]利用电磁波的传播群路径和传播时间的关系进行目标定位,具有很好的精度,但该模型对系统要求较高,需要主站和接收站之间在时域、频域、空域上的严格同步。相对于时差定位,测向定位需要更少的接收站,系统的构成相对简单,对接收站之间的时间同步要求不高,但是其缺点是定位误差比较大。孔若男等^[3]提出了基于天波超视距雷达与角度传感器群进行数据关联的定位精度提升算法,能明显提升方位角的测量精度,但是不能明显提升径向距的估计精度。测向与时差混合定位结合了角度和时差的信息,只需要两个接收站就能实现对目标的定位,且可以得到比测向定位方法更好的精度。张晓玲^[4]提出了利用在高频超视距雷达中比较容易获得的方位角信息,结合时差信息,使用两个接收站来对目标进行定位的无源定位方法,但定位精度不高,因此,通过增加一个接收站以获取更多的目标信息来提高高频雷达对目标的探测精度,但其缺点是系统复杂度提高,接收站的个数增多,解算时需要三个子系统的冗余定位方程进行最邻近匹配法和简化加权最小二乘(SWLS)融合来提高定位精度,计算复杂,实时性降低。

上述方法均通过解析几何方程获得目标位置,实现时算法简单、直观,但对测量噪声和站型分布敏感,测量误差和目标与接收站之间的距离对目标定位的精度影响较大。利用到达时间差(TDOA)与方位角(AZ)的混合定位方法,在解析法求解的过程中,对非线性方程进行线性近似处理,虽然简化了数学计算过程,但不易求得精确解,降低算法的定位精度。

机器学习算法很适合处理这种非线性特征的相关数据。极限学习机(ELM)与其他神经网络算法相比,学习速度更快,输入参数更少,可以避免局部极值问题,具有较好的泛化性能。但也存在隐含层节点数量无法确定、易产生奇点等缺点,核极限学习机(KELM)将激励函数转化为核映射,很好地避免了该问题。

为了发挥测向与时差混合定位算法的优势,同时克服解析法的缺点,提高天波雷达定位的精度和稳定性,本文提出一种基于KELM的测向与时差混合的双基地定位算法,利用混沌变异灰狼优化(CMGWO)算法改进的KELM对两个接收站探测到目标反射回波的TDOA、AZ观测量和目标位置数据进行学习,建立TDOA、AZ和目标经纬度位置

的函数关系,进行目标位置的预测。既充分利用角度和时差混合定位方法接收站的个数少、系统构成相对简单和设备量相对较小的工程实用优点,又利用KELM强大的泛化能力克服解析法求解精度低的缺点,提高了目标的定位精度,同时用CMGWO对KELM的惩罚系数和核参数进行优化,克服KELM算法对参数选择敏感的缺点,进一步提高了KELM定位模型的泛化性能和定位精度。

2 基本原理介绍

2.1 基本灰狼算法介绍

灰狼群的社会等级由上至下依次为 α 狼、 β 狼、 δ 狼和 ω 狼,狼群的狩猎行为主要有跟踪并靠近猎物、追踪包围猎物和攻击猎物。如图1所示,金字塔第一层为种群中的头狼,称为 α ,主要负责群体各项决策事务;金字塔第二层称为 β ,协助 α 做出管理决策;金字塔第三层为 δ , δ 听从 α 及 β 的指令;金字塔最底层称为 ω ,主要负责平衡种群内部关系。灰狼的种群等级在实现群体高效捕杀猎物的过程中发挥着至关重要的作用。捕食过程由 α 带领完成,首先狼群以团队模式搜索、跟踪、靠近猎物,然后从各个方位包围猎物,当包围圈足够小且完善时,狼群在 α 的指挥下由最靠近猎物的 β 、 δ 展开进攻,在猎物逃跑时,其余个体进行补给,实现群狼包围圈的跟随变换移动,从而对猎物不断实施各个方向的攻击,最终捕获猎物。灰狼优化(GWO)^[5]算法是仿灰狼社会等级和狩猎行为提出的一种新的群智能优化算法。




图1 灰狼群等级金字塔

Fig. 1 Hierarchy pyramid of grey wolf

2.2 TDOA/AZ 定位的数学模型

侧向与时差混合定位方法同时基于TDOA和AZ这两个最基本的观测量。接收站分开放置,同时接收目标回波,通过测量目标反射信号到达两个接收站的TDOA信息以及AZ信息对目标进行定位。系统平面示意图如图2所示,目标的返回散射

回波经由电离层反射到接收站 R_1 和接收站 R_2 ，根据球面三角公式，通过解算目标到接收站的地面距

离与天波群路径之差和方位角的几何关系，进行目标定位。




图2 双基地天波雷达无源定位模型

Fig. 2 Bistatic sky-wave radar passive location model

设 R_1 站经纬度为 (L_1, B_1) , R_2 站经纬度为 (L_2, B_2) , 目标 T 的位置为 (L_T, B_T) , r 为到目标反射回波到两个接收站的天波群路径距离差, c 为电波传播速度, 根据两个接收站测量到的电波传播 TDOA 信息可建立以下距离方程, 即

$$r = c\tau = P'_2 - P'_1 = \frac{\sigma_1 a \sqrt{1 + e'^2}}{k_1 (1 + e'^2 \cos^2 B_1)} - \frac{\sigma_2 a \sqrt{1 + e'^2}}{k_2 (1 + e'^2 \cos^2 B_2)}, \quad (1)$$

式中 τ 为时间差, a 为地球长半轴, 取 6378.2450 km, $e'^2 = (a^2 - b^2)/b^2$, 是第二偏心率的平方, b 是地球短半轴, 取 6356.8630 km。 $\sigma_i = \arccos[\sin B_T \sin B_i + \cos B_T \cos B_i \cos(L_T - L_i)]$, $i = 1, 2$ 。根据接收站测得目标回波的 AZ 信息可建立方程

$$\begin{cases} \alpha_i = \arctan \left[\frac{(L_T - L_i) \times \cos(B_T)}{B_T - B_i} \right] \\ \theta_i = \begin{cases} \alpha, & \alpha \in (0, 90) \\ \alpha + 180, & \alpha \in (90, 180) \\ \alpha + 360, & \alpha \in (180, 360) \\ 90, & B_T = B_i, L_T > L_i \\ 270, & B_T = B_i, L_T < L_i \end{cases} \end{cases}, \quad (2)$$

式中 α 为象限角, θ 为方向角, $i = 1, 2$ 。求解由 (1) 和 (2) 式构成的方程组可得到目标估计位置 (L_T, B_T) 。

2.3 基于核极限学习机的 TDOA/AZ 定位模型

利用 KELM 对上述复杂函数关系进行高度非线性自适应拟合, 利用 KELM 对接收站探测到目标反射回波的 TDOA、AZ 数据和目标位置数据进行学习, 建立 TDOA、AZ 和目标经纬度位置的函数关系, 进行目标位置的预测。输入层由接收站提供的 TDOA 测量值和两个 AZ 测量值组成, 输入向

量 \mathbf{V} 可以表示为

$$\mathbf{V} = (\tau, \theta_1, \theta_2), \quad (3)$$

式中 τ 为两个接收站测量到的目标反射回波的时间差, θ_1 和 θ_2 是两个接收站分别测量目标反射回波的方向角。输出向量 \mathbf{P} 为目标经纬度, 可表示为

$$\mathbf{P} = (L_T, B_T), \quad (4)$$

式中 L_T 表示目标的经度, B_T 表示目标的纬度。

3 基于改进灰狼算法优化核极限学习机的定位建模

3.1 灰狼算法的改进

GWO 算法在解决复杂问题时易陷入局部最优解^[6], 全局搜索能力不足。为了进一步提高灰狼算法的寻优性能, 加快算法的收敛速度, 同时避免算法陷入局部最优, 本文采用多种策略对灰狼算法进行优化, 有效地改善了灰狼算法的寻优性能和寻优精度, 具体改进点如下。

1) 基于分段线性混沌映射优化初始种群

种群初始化对 GWO 算法的收敛速度和解质量影响很大, 如果采取随机初始化的方法, 虽然在一定程度上能保证种群的随机分布, 但会影响算法的全局搜索能力和收敛速度。混沌能够在一定范围内按其自身规律不重复地遍历所有状态, 提高算法的全局搜索能力。

与常见的 Logistic 映射、Tent 映射以及 Chebyshev 映射相比, 分段线性映射 (PLM)^[7] 具有表述简单、分布函数均匀和统计特性可控的显著特性, 因此, 本文将分段线性映射的混沌特性应用到灰狼算法的种群初始化中, 优化过程如下。

① 根据 (5) 式产生 N 个 M 维的向量, M 维中

每个分量为 $0 \sim 1$ 之间的混沌量, N 个向量表示为 $\mathbf{Z}_1, \dots, \mathbf{Z}_i, \dots, \mathbf{Z}_N$, 其中 $\mathbf{Z}_i = (z_{i1}, \dots, z_{ij}, \dots, z_{iM})$, 元素根据(5)式更新, 公式为

$$z_{i+1j} = \begin{cases} \frac{z_{ij}}{p}, & z_{ij} \in (0, p) \\ \frac{z_{ij} - p}{0.5 - p}, & z_{ij} \in [p, 0.5) \\ \frac{1 - p - z_{ij}}{0.5 - p}, & z_{ij} \in [0.5, 1 - p) \\ \frac{1 - z_{ij}}{p}, & z_{ij} \in [1 - p, 1) \end{cases}, \quad (5)$$

式中: $i \in [1, N]$ 的整数, N 表示灰狼群体的种群数量; $j \in [1, M]$ 的整数, M 表示灰狼个体初始位置变量的维度; p 为控制参数, $p \in (0, 0.5)$ 。

② 将各分量载波到灰狼初始化位置变量的取值范围上, 形成初始种群 \mathbf{X} , \mathbf{X} 中元素为

$$X_{ij} = a_j + (b_j - a_j)z_{ij}, \quad (6)$$

式中: $i \in [1, N]$ 的整数, N 表示灰狼群体的种群数量; $j \in [1, M]$ 的整数, M 表示灰狼个体初始位置变量的维度; b_j 和 a_j 分别表示灰狼个体位置变量的第 j 维元素的最大值和最小值。

2) 基于自适应柯西变异优化迭代过程的最优种群位置

灰狼算法在收敛之前, 全局最优灰狼个体 A_P 总是在多个候选位置中摆动, 容易陷入局部最优。变异算子可以提高 A_P 的搜索空间, 避免算法陷入局部最优, 同时也能保持种群个体的多样性。为了降低标准 GWO 算法出现早熟和陷入局部最优的概率, 本文对全局最优灰狼位置 A_P 进行自适应柯西变异(ACM)^[8-9], ACM 操作综合考虑灰狼种群迭代过程中的个体最优位置 G_P 与全局最优解 A_P 的距离和进化代数的关系, 算法迭代开始前, 设置柯西变异概率为 p_m , 每当完成一次迭代, 计算出新的全局最优解 A_P 后, 按概率 p_m 来决定是否对 A_P 进行柯西变异操作。过程如下。

① 生成一个随机数 $r_m = \text{rand}(0, 1)$, 如果 $r_m < p_m$, 则转入步骤②, 否则, 转入步骤③。

② 对全局最优解 A_P 进行变异操作, 产生变异 A_P^* , 若变异后 $f(A_P^*)$ 优于 $f(A_P)$, 则取而代之。ACM 具体操作为

$$A_P^*(j) = A_P(j) + D(j) \cdot F(x_m), \quad (7)$$

式中 $j \in [1, M]$ 的整数, M 表示灰狼位置向量的维度。根据下式求出各维变异权重的平均值 $D(j)$, $F(x_m)$ 是柯西分布函数, 表达式分别为

$$D(j) = \frac{\sum_{i=1}^N |C_1 \times A_P(j) - G_P(i, j)|}{N}, \quad (8)$$

$$F(x_m) = \frac{1}{\pi} \arctan(x_m) + \frac{1}{2}, \quad (9)$$

式中: C_1 为随机产生的向量系数, $C_1 \in (0, 2)$; $i \in [1, N]$ 的整数, N 表示灰狼群体的种群数量; $j \in [1, M]$ 的整数, M 表示灰狼位置向量的维度。变异种子 x_m 在各维度上的值为

$$x_m(j) = \exp\left(-\frac{\lambda t}{t_{\max}}\right) \left[1 - \frac{r(j)}{r_{\max}}\right], \quad (10)$$

式中: λ 是常数, 文中取 $\lambda = 10$; t 为进化代数, t_{\max} 是最大进化代数; r_{\max} 是个体最优值各维间最大距离; $r(j)$ 是 M_P 到 A_P 上每一维度的距离。计算公式为

$$r(j) = |A_P(j) - M_P(j)|, \quad (11)$$

式中 $M_P(j)$ 是个体极值 G_P 在各维度上的平均值, 其值为

$$M_P(j) = \frac{\sum_{i=1}^N G_P[i][j]}{N}, \quad (12)$$

式中: $j = 1, 2, \dots, D$; $G_P[i][j]$ 是第 i 只灰狼在第 j 维度上最优或者最差位置。

③ 进入下一轮 CMGWO 迭代。

3) 改进非线性收敛因子策略

标准 GWO 算法中, 局搜索能力和局部搜索能力在很大程度上依赖于收敛因子 a 的取值。收敛因子 a 随着迭代次数的增加, 从 2 线性递减到 0, 反映灰狼群体先扩大包围圈寻找优质猎物, 再缩小包围圈, 完成种群协作围猎的过程。GWO 算法的实际进化搜索过程是非线性变化的, 收敛因子 a 的线性递减策略不能体现出灰狼群体实际的协作围猎过程, 本文采用非线性方法^[10]更新收敛因子 a , 公式为

$$a = 2 \cos\left[\left(\frac{t}{t_{\max}}\right) \cdot \frac{\pi}{2}\right], \quad (13)$$

式中: t 为当前迭代次数; t_{\max} 为最大迭代次数; 由(13)式可知, 收敛因子 a 随进化迭代次数增加而非线性动态变化。随着种群搜索围猎进程的推进, 围猎区间非线性缩小, 变化速率先慢后快, 很好地协调了算法的全局搜索能力和局部搜索能力, 种群得以快速逼近最优解。

3.2 CMGWO-KELM 多基地天波超视距雷达目标定位建模

传统 ELM 的隐含层数目无法确定^[11-13], 影响其预测性能, 因此, 根据支持向量机(SVM)的原理, 将核函数引入到 ELM 模型, 从而提出了 KELM 算

法^[14]。由于核函数的引入, KELM 算法对参数选择敏感^[15], 故本文采用 CMGWO 对 KELM 预测精度影响较大的核参数 γ 和惩罚系数 C 进行优化, 提出基于 CMGWO-ELM 的天波雷达定位模型。模型实现和优化流程如图 3 所示, 具体步骤如下。

1) 数据预处理

采集若干组实验数据, 数据信息包括各接收站接收到目标反射回波信号的 TDOA 和 AZ 信息。将若干组数据, 进行一定的预处理后, 按比例分成两组, 分别作为训练集和测试集。对数据进行归一化处理。

2) CMGWO 网络参数优化

设置灰狼种群规模, 搜索空间范围, 最大迭代次数和柯西变异概率 p_m , 随机初始化灰狼种群。灰狼

个体位置向量对应 KELM 参数 (C, γ) 。

3) 适应度评价函数为

$$f = m \times \left(\sum_{i=1}^M |P_i^* - P_i| \right), \quad (14)$$

式中 M 为训练样本数目, P^* 为模型预测的目标位置, P_i 为实际目标所在位置, m 为常数, 且不为零。

4) CMGWO-KELM 定位模型的实现

将通过 CMGWO 优化算法得到最优灰狼个体解码 KELM 最优模型结构参数, 实现 CMGWO-KELM 定位模型。

5) 预测目标位置

将测试集输入到训练好的 CMGWO-KELM 天波雷达定位模型, 预测目标位置, 并将预测目标位置与目标实际位置进行对比, 检验模型的有效性和可靠性。

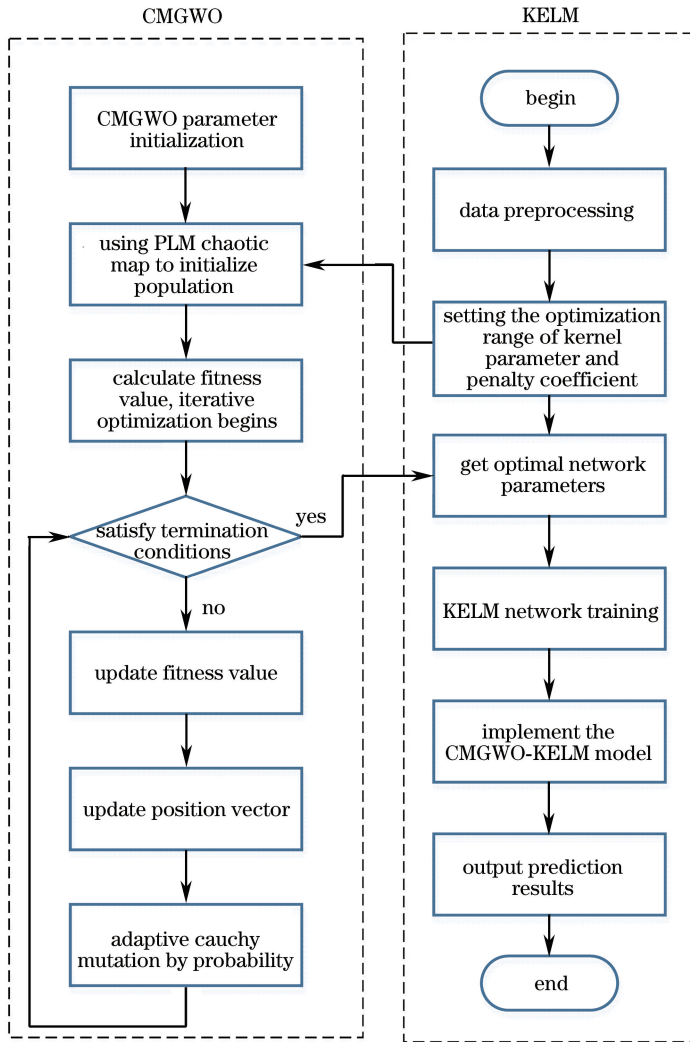


图 3 CMGWO-KELM 天波雷达定位模型实现流程图

Fig. 3 Location model implementation flow chart of sky-wave radar based on CMGWO-KELM

4 仿真与性能分析

4.1 评价指标

通过寻优结果精确度(AC)来评价算法CMGWO的性能,该指标反映了算法所得结果与问题全局最优解的接近程度。问题的理论最优解与算法所求最优解越接近,则说明算法的寻优性能越好。假设一个问题的全局最优解是 X_o ,第 t 次迭代后算法所找到的最优解为 X_b ,则所求结果的精确度定义为

$$A_c = |f(X_o) - f(X_b)|, \quad (15)$$

式中 A_c 为寻优结果的精确度。

采用误差绝对值(AE)来评价各个模型预测的精确度,AE反映了绝对误差测量值相对真值的偏离程度,偏离程度越小,说明结果越精确。

$$A_E = |P_n - P_n^*|, \quad (16)$$

式中 A_E 为误差的绝对值, P_n 为第 n 个测试样本实际目标位置, P_n^* 为第 n 个测试样本预测的目标位置。从(16)式可以看出, A_E 值越小,说明目标预测位置与目标实际位置的偏差越小,那么定位的精度也就越高。

4.2 CMGWO 算法性能分析

为了测试本文CMGWO算法的性能,本文选取CEC2005上的4个基准测试函数进行仿真实验分析,利用CMGWO算法对4个基准测试函数进行寻优求解,并与GWO算法和粒子群优化(PSO)算法

的寻优结果进行比较。表1给出了基准测试函数的函数名、搜索范围和理论最优值,其中, f_1 和 f_2 是连续单峰函数,仅有一个极值,即局部极值就是全局极值,在验证算法寻优快速性和寻优精度等方面有较好的测试能力; f_3 和 f_4 是连续多峰函数,其局部极值点会随着函数维数的增加而呈指数倍增长,容易造成算法陷入局部最优导致停滞,在验证算法局寻优能力和收敛速度等方面有较好的测试能力。以上测试函数只有一个全局最优值点,而且最优值均为0。

为了比较结果的公平性,针对4个测试函数的三种算法的参数设置如下:种群规模为50,最大迭代次数为200,维度为10。为避免寻优效果的偶然性,同时也为了证明CMGWO算法的稳定性,对每种测试函数分别运行20次。特别地,CMGWO算法中PLM混沌映射的控制参数 $p=0.2$,柯西变异概率 $p_m=0.5$,PSO算法的学习因子 $c_1=c_2=2$, $\omega=0.6$ 。

表1 基准测试函数

Table 1 Benchmarking function

No.	Function name	Search scope	Optimal value	Peak
f_1	Sphere	$[-100, 100]$	0	Unimodal
f_2	Schwefel 2,22	$[-10, 10]$	0	Unimodal
f_3	Rastrigin	$[-5.12, 5.12]$	0	Multimodal
f_4	Ackley	$[-32, 32]$	0	Multimodal

表2 改进GWO算法的实验结果比较

Table 2 Comparison of experimental results by improved GWO algorithm

Function	Algorithm	Optimal value	Worst value	Average value	Standard deviation
f_1	PSO	0.054	91.180	22.093	24.477
	GWO	8.820×10^{-30}	1.160×10^{-25}	1.722×10^{-26}	3.072×10^{-26}
	CMGWO	3.957×10^{-36}	1.458×10^{-32}	2.052×10^{-33}	3.727×10^{-33}
f_2	PSO	0.017	1.614	0.158	0.295
	GWO	4.555×10^{-17}	3.943×10^{-15}	1.040×10^{-15}	1.192×10^{-15}
	CMGWO	1.142×10^{-20}	1.195×10^{-18}	2.646×10^{-19}	2.953×10^{-19}
f_3	PSO	2.987	15.919	7.927	3.289
	GWO	0.000	12.172	2.671	3.105
	CMGWO	0.000	6.233	0.661	1.685
f_4	PSO	0.004	5.735	2.704	1.386
	GWO	5.063×10^{-14}	3.597×10^{-13}	1.236×10^{-13}	7.578×10^{-14}
	CMGWO	7.994×10^{-15}	2.931×10^{-14}	1.415×10^{-14}	4.659×10^{-15}

对三种算法运行后的最优结果求出最优值、最差值、平均值和标准差,测试结果如表2所示。最优值反映算法的全局寻优能力,最差值反映算法是否容易陷入局部极值,平均值反映了算法在给定迭代

次数时算法所能达到的收敛精度,标准差反映了算法的稳定性和稳健性。最优值、最差值和平均值越接近基准测试函数的理论最优值,算法的寻优性能、搜索能力和收敛精度越好,标准差越小算法的稳定

性和稳健性越高,越不易陷入局部极值。

从表 2 比较结果可知,与标准 GWO 算法及 PSO 算法相比,本文 CMGWO 算法在 4 个基准测试函数上进行的 20 次实验中均能一致收敛到较好的全局最优解。除了在 f_3 函数上,GWO 算法和 CMGWO 算法在最优情况下均能收敛到全局最优值 0,但是从其寻优结果的最差值、平均值和标准差上来看,三种算法在寻优时都容易陷入局部极值。这是因为 f_3 函数有非常多的局部极小值点,而仅有一个全局最小点,即 $[0,0]$,在这个点处的函数的值为 0,群智能算法在对其进行寻优时很容易陷入局部极值。但相对而言,在 f_3 函数的寻优上,CMGWO 算法的全局搜索能力和收敛精度更高,算法的稳定性也更好。在其余测试函数上,标准 GWO 算法的寻优结果非常接近理论最优值,寻优性能远胜于 PSO 算法,而本文提出的 CMGWO 算法求得的最优值又比标准 GWO 算法求得的最优值提高了几个数量级,表现出极好的搜索能力和稳定性。由上述比较结果可以看出,CMGWO 算法比 GWO 算法和 PSO 算法在测试函数上具有更高的寻优精度,为基于 CMGWO-KELM 的天波雷达定位模型的建立奠定了良好的基础。

4.3 CMGWO-LELM 模型性能分析

接收站 R_1 站经纬度为 $(30.5443^\circ\text{N}, 114.3660^\circ\text{E})$, R_2 站经纬度为 $(31.9913^\circ\text{N}, 112.8638^\circ\text{E})$,两接收站之间的距离约为 215 km,两接收站形成的夹角约为 80° ,目标与接收站之间的距离为 300 ~ 2000 km,系统 TDOA 的测量误差为 50 ~ 100 ns, AZ 的测量误差为 $0.5^\circ \sim 1^\circ$,各站的时间测量以及角度测量误差均相互独立,电离层高度的测量误差在 0 ~ 3.5 km 的范围内变化。采集 150 组数据,随机选择 100 组数据作为训练集,剩余 50 组作为测试集。为了验证 CMGWO-KELM 天波雷达定位模型的有效性,将测试数据分别输入训练好的 CMGWO-KELM、GWO-KELM 模型和解析法定位模型。为了公平起见,两种神经网络定位模型的基本参数保持一致:种群规模为 5,最大迭代次数为 30,CMGWO-KELM 模型中的混沌映射控制参数为 0.2,柯西变异概率为 0.5,GWO-KELM 模型仅将优化函数改成标准 GWO 算法,解析定位模型的测试数据与本文神经网络模型的测试数据相同。

由图 4 可知,CMGWO-KELM 模型预测结果十分接近于真实值,各点定位均表现出非常高的拟合精度。图 5 是三种定位模型的预测绝对误差对比

图,横坐标是测试样本,纵坐标是该目标样本预测位置与实际位置的误差绝对值。由图 5 可知,CMGWO-ELM 定位模型的经纬度和径向距离预测误差小于其他两种定位模型,预测结果与真实值最为接近。三种模型预测精度的平均优异度顺序为 CMGWO-KELM、GWO-KELM、解析法。实验结果表明,CMGWO-KELM 具备更高的定位精度。

从时间性能上分析,达到图 5 所示的定位误差效果时,解析法定位模型平均耗时为 0.2192 s, GWO-KELM 定位模型平均耗时为 0.7541 s, CMGWO-KELM 平均耗时为 0.8483 s。这说明 KELM 神经网络定位模型比解析法定位模型的实时性差,但定位的精度大大提升。对实时性要求不高,但精度要求高的应用场景,KELM 神经网络定位模型仍具有工程实用价值。

总的来说,在 KELM 定位模型中,基于 CMGWO 算法改进 KELM 的定位模型(即 CMGWO-ELM 定位模型)的定位精度高于基于标准 GWO 算法改进 KELM 的定位模型(即 GWO-ELM 定位模型),虽然定位速度略有下降,但仍然在可接受范围内。解析法定位模型通过数学算法求解 2.2 节所述的非线性方程实现目标定位,虽然算法实现简单、实时性较好,但在解析法求解的过程中,对非线性方程进行线性近似处理,因此,算法的定位精度较低。GWO-KELM 定位模型和 CMGWO-KELM 定位模型通过对输入数据的训练和学习,建立 TDOA、AZ 和目标经纬度位置的函数关系,实现目标位置的预测,克服了解析法求解精度低的缺点,算法的定位精度相对较高,但由于需要训练神经网络,算法的实时性有所下降。因此,从定位精度上评价,本文提出的 CMGWO-KELM 具备更高的预测精度,验证了该模型的有效性和高精度性。

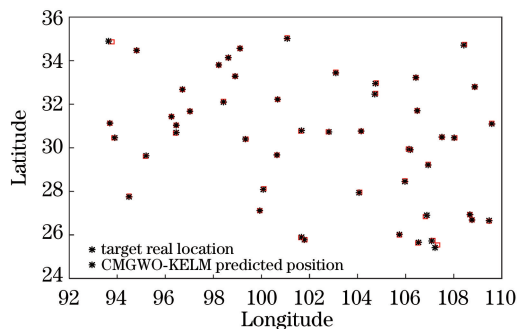


图 4 CMGWO-KELM 的目标预测位置与真实位置的对比
Fig. 4 Comparison of target prediction position and real position by CMGWO-KELM model

表 3 将上述基于方位角与时间差混合的三种定位模型与仅采用方位角信息进行目标定位^[3]的解析法模型进行对比,给出不同方法的径向距离误差结果。其中,方法 1 的径向距离误差结果是直接引用文献[3]中的实验结果,方法 2、3、4 的径向距离误差值是图 5(b)中 50 组测试目标的径向距离误差绝对值的平均值。方法 2、3、4 与方法 1 的比较结果表明,相比于基于方位角的侧向定位方法,基于方位角

与时间差混合的定位方法能更加准确有效地预测目标位置;方法 3、4 和方法 1、2 的比较结果表明,神经网络定位模型比解析法定位模型在目标定位性能上更有优势;方法 3 和方法 4 的比较结果表明,CMGWO 比 GWO 的遍历性和寻优性能更好,使得模型 CMGWO-KELM 对测试样本的定位结果最好,与真实值更加接近,说明本文提出的 CMGWO-KELM 定位模型是可行、有效、高精度的。

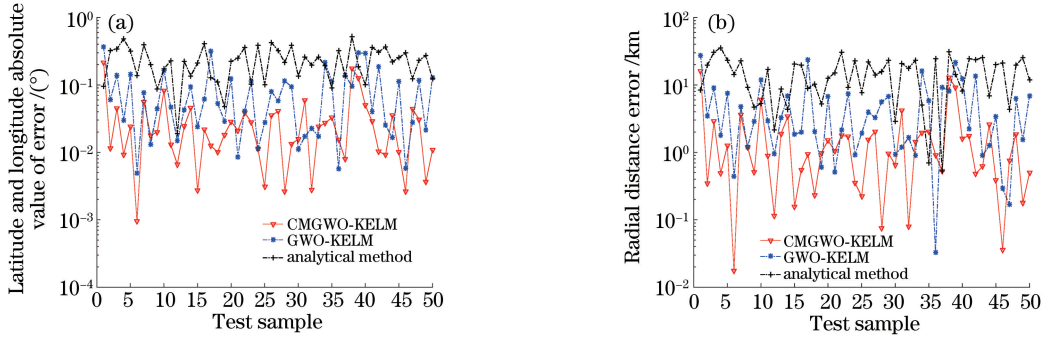


图 5 三种模型的预测误差绝对值。(a)经纬度预测误差;(b)径向距离预测误差

Fig. 5 Absolute value of the prediction error of the three models. (a) Longitude and latitude prediction error; (b) radial distance prediction error

表 3 不同预测模型的误差绝对值对比

Table 3 Absolute value comparison of different prediction models

No.	Method	Radial distance error /km
1	AZ Analytical method location model	20.360
2	TDOA/AZ Analytical method location model	12.691
3	TDOA/AZ-GWO-KELM location model	9.707
4	TDOA/AZ-CMGWO-KELM location model	2.944

5 结 论

针对天波雷达侧向与时差混合定位方法存在的问题,建立基于 CMGWO 算法优化 KELM 的天波雷达定位模型, KELM 用于构建目标预测模型, CMGWO 用于 KELM 参数寻优。采集了 100 组数据用于仿真实验,测试结果表明,CMGWO 与标准 GWO 算法相比,收敛速度更快,寻优能力更强; CMGWO-KELM 与其他模型相比,预测精度更高,模型的泛化能力更好,具有可行性和精度上的优越性,为天波雷达的目标定位提供了一种新方法。

参 考 文 献

- [1] Guo X, Ni J L, Liu G S. Architecture and signal processing of sky wave over-the-horizon radar [J]. Radio Science, 2003, 38(5): 1-14.
- [2] Song J, Zhao Z Y, Zhou C, *et al.* Study on sky-wave over-the-horizon location model of high frequency

multistatic system [J]. Systems Engineering and Electronics, 2011, 33(2): 272-275.

宋君, 赵正予, 周晨, 等. 多基高频天波超视距定位模型 [J]. 系统工程与电子技术, 2011, 33(2): 272-275.

- [3] Kong R N, Cheng Y M, Liang Y, *et al.* Mode identification and location improvement based on data association of OTHR and azimuth-only sensors [J]. Acta Aeronautica et Astronautica Sinica, 2012, 33(6): 1061-1069.
孔若男, 程咏梅, 梁彦, 等. 基于 OTHR 与纯角度传感器群数据关联的模式辨识与定位精度提升 [J]. 航空学报, 2012, 33(6): 1061-1069.
- [4] Zhang X L. Application of passive TDOA location technology in HF radar [D]. Xi'an: Xidian University, 2013: 6-9.
张晓玲. 无源时差定位技术在高频雷达中的应用 [D]. 西安: 西安电子科技大学, 2013: 6-9.
- [5] Mirjalili S, Mirjalili S M, Lewis A. Grey wolf optimizer [J]. Advances in Engineering Software,

- 2014, 69: 46-61.
- [6] Zhang X M, Kang Q, Cheng J F, *et al.* A novel hybrid algorithm based on biogeography-based optimization and grey wolf optimizer [J]. *Applied Soft Computing*, 2018, 67: 197-214.
- [7] Ghebleh M, Kanso A, Stevanović D. A novel image encryption algorithm based on piecewise linear chaotic maps and least squares approximation [J]. *Multimedia Tools and Applications*, 2018, 77(6): 7305-7326.
- [8] Zou Y N, Liu P X, Yang C S, *et al.* Collision detection for virtual environment using particle swarm optimization with adaptive cauchy mutation [J]. *Cluster Computing*, 2017, 20(2): 1765-1774.
- [9] Kang L L, Dong W Y, Song W J, *et al.* Non-inertial opposition-based particle swarm optimization with adaptive elite mutation [J]. *Journal on Communications*, 2017, 38(8): 66-78.
康岚兰, 董文永, 宋婉娟, 等. 无惯性自适应精英变异反向粒子群优化算法 [J]. *通信学报*, 2017, 38(8): 66-78.
- [10] Liu C A, Wang X P, Liu C Y, *et al.* Three-dimensional route planning for unmanned aerial vehicle based on improved grey wolf optimizer algorithm [J]. *Journal of Huazhong University of Science & Technology (Natural Science Edition)*, 2017, 45(10): 38-42.
柳长安, 王晓鹏, 刘春阳, 等. 基于改进灰狼优化算法的无人机三维航迹规划 [J]. *华中科技大学学报 (自然科学版)*, 2017, 45(10): 38-42.
- [11] Bai J J, Sun Q, Jing S B, *et al.* Robust extreme learning machine and its application in analysis of near infrared spectroscopy data [J]. *Laser & Optoelectronics Progress*, 2015, 52(10): 103002.
白俊健, 孙群, 井诗博, 等. 稳健极限学习机及其在近红外光谱分析中的应用 [J]. *激光与光电子学进展*, 2015, 52(10): 103002.
- [12] Zhang H D, Li G R, Li R C, *et al.* Determination of tea polyphenols content in puerh tea using nearinfrared spectroscopy combined with extreme learning machine and GA-PLS algorithm [J]. *Laser & Optoelectronics Progress*, 2013, 50(4): 043001.
张海东, 李贵荣, 李若诚, 等. 近红外光谱结合极限学习机和 GA-PLS 算法检测普洱茶茶多酚含量 [J]. *激光与光电子学进展*, 2013, 50(4): 043001.
- [13] Xu Y, Wei Z Y. An improved traffic sign image recognition algorithm [J]. *Laser & Optoelectronics Progress*, 2017, 54(2): 021001.
徐岩, 韦镇余. 一种改进的交通标志图像识别算法 [J]. *激光与光电子学进展*, 2017, 54(2): 021001.
- [14] Wong C M, Vong C M, Wong P K, *et al.* Kernel-based multilayer extreme learning machines for representation learning [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2018, 29(3): 757-762.
- [15] Zhou C, Yin K L, Cao Y, *et al.* A novel method for landslide displacement prediction by integrating advanced computational intelligence algorithms [J]. *Scientific Reports*, 2018, 8: 7287.