

基于改进 ALO-RBF 的高频地波雷达海杂波预测模型

张先芝, 尚 尚, 戴圆强, 杨 童, 刘 明
(江苏科技大学海洋学院 镇江 212100)

摘要: 高频地波雷达是海上动目标检测的重要手段, 其中海杂波是影响海面目标检测性能的主要因素。为了提高海杂波的预测精度进而有效抑制海杂波, 本文提出了一种基于改进蚁狮算法 (Ant Lion Optimizer, ALO) 优化 RBF 神经网络的海杂波预测模型 (MGPALO-RBF, Multiple elites dynamic guidance Ant Lion Optimizer based on Gaussian difference variation-based learning with Perturbation factor-radial basis function)。由于标准蚁狮算法具有易陷入局部最优且收敛速度慢的缺点, 本文在蚂蚁进行随机行走的过程中加入扰动因子以增加种群的活跃性和多样性, 并提出多个精英动态引导机制, 强化算法前期的探索能力和后期的开发能力, 同时对种群中较差蚁狮进行高斯差分变异以提高算法的收敛速度。仿真结果表明: 改进的蚁狮算法在对比算法中具有更高的收敛精度和收敛速度, MGPALO-RBF 模型具有更好的海杂波预测性能。

关键词: 高频地波雷达; 海杂波; RBF 神经网络; 蚁狮算法

中图分类号: TN957.54 文献标志码: A 文章编号: 2095-1000(2023)01-0111-09

DOI: 10.12347/j.ycyk.20220411002

引用格式: 张先芝, 尚尚, 戴圆强, 等. 基于改进 ALO-RBF 的高频地波雷达海杂波预测模型[J]. 遥测遥控, 2023, 44(1): 111-119.

Sea clutter prediction model of high frequency surface wave radar based on improved ALO-RBF neural network

ZHANG Xianzhi, SHANG Shang, DAI Yuanqiang, YANG Tong, LIU Ming
(Ocean College, Jiangsu University of Science and Technology, Zhenjiang, 212100, China)

Abstract: High-frequency ground wave radar is an important means of detecting moving targets on the sea, among which sea clutter is the primary factor that influences the function of sea surface target detection. For the sake of enhancing the prediction precision of sea clutter and validly restrain the sea clutter, this paper proposes a sea clutter prediction model (MGPALO-RBF) based on the improved ant lion algorithm to optimize the RBF neural network. In order to ameliorate the weak point of the ant lion algorithm that it sink easily into the local optimum and the convergence velocity is slow, a disturbance factor is added to increase the activity and variety of the population during the process of stochastic walk of the ants; multiple elite dynamic guidance mechanisms are put forward to intensify the searching capability of the algorithm in the prophase and the exploit ability in the later stage; Gaussian difference mutation is put forward on the poor ant lion in the population to enhance the convergence velocity of the algorithm. The simulation results make clear that the mended ant lion algorithm has higher convergence precision and constriction speed in the contrast algorithm, and the optimized model has a better effect in sea clutter prediction.

Keywords: High frequency ground wave radar; Sea clutter; RBF neural network; Antlion algorithm

Citation: ZHANG Xianzhi, SHANG Shang, DAI Yuanqiang, et al. Sea clutter prediction model of high frequency surface wave radar based on improved ALO-RBF neural network [J]. Journal of Telemetry, Tracking and Command, 2023, 44(1): 111-119.

引 言

高频地波雷达 (High Frequency Surface Wave

Radar, HFSWR) 具有探测距离远、探测精度高、实时性强等特点^[1], 广泛应用于海上目标的检测。海杂波是雷达回波中的主要成分, 是目标检测的

基金项目: 国家自然科学基金项目 (61801196); 国防基础科研计划稳定支持专项项目 (JCKYS2020604SSJS010); 江苏省研究生科研与实践创新计划资助项目 (SJCX22_1889)

通信作者: 尚尚 (shangshang@just.edu.cn)

收稿日期: 2022-04-11 修回日期: 2022-05-21

一个重要挑战。在抑制海杂波方面, 传统的子空间类方法和循环对消类方法都难以区分一阶多普勒频率附近的目标^[2], 而基于海杂波形成机理的非线性预测方法能够很好地解决这一问题。该类方法是从海杂波的混沌特性出发^[3], 由于海杂波的形成机理可以通过神经网络强大的学习能力进行拟合, 因此将神经网络当作一个函数估计器, 无限逼近海杂波输入和输出之间的映射关系, 即通过径向基神经网络模型实现对海杂波的非线性预测^[4]。

精确地预测海杂波是后续进行目标检测的重要保障。由于径向基神经网络模型的参数选取直接影响该模型对海杂波的预测效果^[5], 为了提高径向基神经网络模型的预测精度, 保证网络模型的初始化参数设置为最优值, 本文采用蚁狮算法对神经网络模型的参数进行优化, 包括径向基函数的数据中心、扩展常数及隐含层与输出层之间的连接权重^[6]。

为提高网络模型的总体性能从而更加精确地预测海杂波, 使用蚁狮算法对网络模型进行优化。蚁狮算法是模仿蚂蚁和蚁狮的关系而产生的一种智能优化算法^[7]。文献[8,9]证明了蚁狮算法在各种优化问题上具有卓越的性能。由于这类群智能算法具有参数设置少、容易实现、操作简单等优点, 在不同领域得到了广泛的应用, 受到了人们越来越多的关注。为改善蚁狮算法收敛速度慢、在优化时难以跳出局部最优等问题, 本文提出了一种基于高斯差分变异带扰动因子且多个精英动态引导的蚁狮算法(MGPALO)。为了丰富蚂蚁种群的多样性, 在随机游走中加入扰动因子; 多个精英动态引导机制有助于算法更好地平衡探索能力和开发能力; 在迭代过程中对较差蚁狮个体进行高斯差分变异有助于算法跳出局部最优。将改进后的蚁狮算法用于对径向基神经网络模型的优化, 进一步提高了该模型对于海杂波的预测效果。

1 蚁狮优化算法

蚁狮是一种捕食蚂蚁的肉食性昆虫, 在捕猎过程中, 蚁狮通过在沙土中构造漏斗形的陷阱诱捕猎物, 等待随机游走的蚂蚁进入陷阱后, 向坑外刨出沙土以逐渐减小陷阱范围, 使得猎物滑入陷阱底端, 防止其逃离进而将其捕食。蚁狮优化算法是根据蚁狮猎捕蚂蚁的捕食机制及其互动关

系而产生的一种智能优化算法。

蚂蚁由于觅食行为会在可搜索空间内进行随机游走。蚂蚁的移动由式(1)描述

$$X(t)=[0, L, \text{cumsum}(2r(t_n)-1)] \quad (1)$$

式中, cumsum 表示累计和, t 表示走走步长, n 为最大迭代次数, $r(t)$ 为一个随机函数, 由式(2)给出

$$r(t)=\begin{cases} 1, & \text{rand}(*)>0.5 \\ 0, & \text{rand}(*)\leq 0.5 \end{cases} \quad (2)$$

式中, $\text{rand}(*)$ 为 $[0,1]$ 内均匀分布函数生成的随机数。

规定蚂蚁在可行搜索范围内进行随机游走更新蚂蚁位置, 为了防止蚂蚁跳出搜索空间, 需要对式(1)生成的蚂蚁位置进行归一化处理。通过式(3)标准化

$$X_i^t = \frac{(X_i^t - a_i)(D_i^t - C_i^t)}{(b_i - a_i)} + C_i^t \quad (3)$$

式中, X_i^t 表示 i 维变量在迭代次数为 t 时的归一化状态因子, a_i 和 b_i 分别表示 i 个变量随机游走的步长最小值和步长最大值, C_i^t 和 D_i^t 分别表示第 i 个变量在迭代次数为 t 时的下界值和上界值。

蚂蚁的位置更新公式由式(4)定义

$$A_i^t = \frac{R_A^t + R_E^t}{2} \quad (4)$$

式中, A_i^t 为第 i 只蚂蚁在迭代次数为 t 时更新后的位置, R_A^t 表示第 i 只蚂蚁在迭代次数为 t 时围绕轮盘赌所选定的蚁狮的随机游走位置, R_E^t 表示第 i 只蚂蚁在 t 代时围绕精英蚁狮的随机游走位置。

蚂蚁种群更新位置后, 通过适应度函数评估蚂蚁和蚁狮的位置。若蚂蚁的适应度值更优, 则蚁狮捕食该蚂蚁。

$$AL_j^t = A_i^t, \text{ if } f(A_i^t) < f(AL_j^t) \quad (5)$$

式中, A_i^t 和 AL_j^t 分别表示当前蚂蚁和蚁狮的位置。蚁狮种群更新后, 若寻得新的最优位置, 则更新精英蚁狮。

2 改进算法

2.1 扰动因子

在基本蚁狮算法中, 同一轮迭代中所有蚂蚁的可搜索范围的大小完全相同, 不利于该算法对于全局最优值的求解, 降低了蚂蚁种群的多样性。对此, 本文提出在蚂蚁的位置更新公式中加入扰动因子, 增强蚂蚁在围绕蚁狮进行随机游走过程中的多样性。扰动因子 γ 由式(6)定义

$$\gamma = [4 \cdot \alpha \cdot (1 - \alpha)]^2 + 0.5, \alpha = \text{rand}(\ast) \quad (6)$$

式中, 扰动因子 γ 在 $[0.5, 1.5]$ 范围内随机分布, 改进式(3)用于增加蚂蚁种群在进行随机游走过程中的多样性和随机性:

$$X_i' = \left[\frac{(X_i' - a_i)(D_i' - C_i')}{(b_i - a_i)} + C_i' \right] \times \gamma \quad (7)$$

扰动因子 γ 使得算法有效避免了陷入局部最优的问题^[10], 在一定程度上提高了种群多样性。

2.2 多个精英动态引导机制

从单个精英蚁狮中能够获得的信息十分有限, 借助灰狼优化算法^[11]的思想, 本文提出在蚂蚁的位置更新过程中采用多个精英蚁狮共同指导机制。在每一次迭代后, 根据适应度值对蚁狮个体进行排序, 将仅次于精英蚁狮的两个蚁狮个体分别定义为 β 和 δ , 在它们的共同带领下, 有助于帮助蚂蚁种群寻找较优解的所在区域, 加快算法的收敛速度。改进式(4)后蚂蚁位置更新由式(8)定义

$$A_i' = \left(1 - \frac{t}{T} \right) \cdot \frac{R_A' + R_{E\beta}' + R_{E\delta}'}{3} + \frac{t}{T} \cdot R_E' \quad (8)$$

式中, A_i' 表示第 t 次迭代第 i 只蚂蚁更新后的位置, R_A' 和 R_E' 分别表示蚂蚁围绕轮盘赌选定的蚁狮和最佳精英蚁狮进行随机游走后的位置, $R_{E\beta}'$ 和 $R_{E\delta}'$ 分别表示蚂蚁围绕较优蚁狮 β 和 δ 进行的随机游走位置。 t 和 T 分别表示当前迭代次数和最大迭代次数。

在不破坏算法开发和探索能力的动态平衡的情况下, 较优蚁狮 β 和 δ 的引入提供了更多的优质位置信息, 帮助算法避免陷入局部最优。蚂蚁的开发和探索能力在不同阶段的侧重比应该不同^[12], 本文根据 t 与 T 的比值关系对位置更新过程进行动态引导。通过当前迭代次数 t 的变化改变式(8)中两部分的比例系数, 即引导蚂蚁位置更新的占比权重。在算法迭代初期, 蚂蚁主要围绕轮盘赌选定的蚁狮以及 β 和 δ 个体进行游走, 随着迭代次数的增加, $\frac{t}{T}$ 的比值逐渐增大, 最佳精英蚁狮对蚂蚁位置更新方向的引导比重也逐渐增强, 轮盘赌选定的蚁狮以及 β 和 δ 个体对蚂蚁的引导占比权重逐渐降低, 到算法迭代后期则主要围绕最佳精英蚁狮进行游走。动态引导机制在一定程度上提高了种群在前期的探索能力和后期的开发能力。

2.3 高斯差分变异

蚂蚁通过轮盘赌选择蚁狮, 只有当蚂蚁的位

置优于所选定的蚁狮的位置, 蚁狮才会进行位置更新。对于种群中适应度较差的蚁狮, 如果围绕其进行随机游走的蚂蚁并未寻得更优位置, 则蚁狮仍保持当前位置。由于轮盘赌选择具有随机性, 仍然会吸引蚂蚁继续开发这些区域, 这在一定程度上会弱化算法的寻优性能, 将造成蚁狮资源的浪费, 不利于算法的收敛。本文提出在每一次迭代中, 通过适应度函数对蚁狮的位置状态进行评估, 按照适应度值进行排序之后, 对适应度值更差的 $0.3N$ 数量的蚁狮个体进行高斯差分变异, 贪婪选择变异前后适应度更优的蚁狮。由式(9)定义

$$X^{t+1} = \frac{f_1 \cdot [X_E - X'] + f_2 \cdot [X_R - X']}{2} \quad (9)$$

式中, X^{t+1} 为变异后的蚁狮位置, X' 为当前的蚁狮位置, X_E 为最佳精英蚁狮的位置, X_R 为随机选择的蚁狮个体的位置, f_1, f_2 是以均值为 0、方差为 1 的高斯分布随机函数产生的缩放系数。传统的差分变异算法中缩放系数为均匀分布函数生成的随机数, 而高斯分布函数的特点是峰值较小^[13], 两边有较长的拖尾, 容易在变异个体上产生更大的扰动。在每一次迭代中, 变异蚁狮的数量为 $0.3N$, 其中, N 为蚁狮种群数。利用适应度值对蚁狮个体进行排序, 对较差蚁狮进行高斯差分变异, 有助于算法跳出局部最优, 提高算法的寻优性能, 加快算法的收敛速度。

3 改进算法的性能测试

为了验证本文提出的 MGPALO 算法的性能, 通过 6 个标准测试函数进行仿真实验, 测试函数设置如表 1 所示。 F_1 和 F_2 为单峰函数, F_3 和 F_4 为维度值可变化的多峰函数, F_5 和 F_6 为维度值固定的多峰函数, 可以更加全面地考察算法的局部搜索能力、全局搜索能力以及处理复杂问题的能力。

实验仿真软件为 MATLAB R2016a。粒子群算法(Particle Swarm Optimization, PSO)是典型的智能优化算法^[14]、海鸥算法(Seagull Optimization Algorithm, SOA)是后来涌现出的新的群智能算法^[15], 在多个领域具有卓越的成效^[16,17]。本文将改进的蚁狮算法(MGPALO)与标准蚁狮算法(ALO)、粒子群算法(PSO)、海鸥算法(SOA)进行对比。针对四种算法, 种群规模统一设置为 30, 最大迭代次数都设置为 500。在 PSO 中的惯性权值 w 和学习因子 c 控制着粒子的探索步长及方向, 此处设置为常用典

表 1 测试函数
Table 1 Test functions

函数表达式	维数	搜索区间	最小值
$F_1(x) = \sum_{i=1}^n \left(\sum_{j=1}^i x_j \right)^2$	30	[- 100, 100]	0
$F_2(x) = \max_i \{ x_i , 1 \leq i \leq n \}$	30	[- 100, 100]	0
$F_3(x) = -20 \exp \left(-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2} \right) - \exp \left(\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i) \right) + 20 + e$	30	[- 32, 32]	0
$F_4(x) = \frac{\pi}{n} \left\{ 10 \sin(\pi y_1) + \sum_{i=1}^n (y_i - 1)^2 [1 + 10 \sin^2(\pi y_{i+1})] + (y_n - 1)^2 \right\} + \sum_{i=1}^n u(x_i, 10, 100, 4)$ $y_i = 1 + \frac{x_i + 1}{4},$ $u(x_i, a, k, m) = \begin{cases} k(x_i - a)^m, & x_i > a \\ 0, & -a < x_i < a \\ k(-x_i - a)^m, & x_i < -a \end{cases}$	30	[- 50, 50]	0
$F_5(x) = \sum_{i=1}^{11} \left[a_i + \frac{x_1(b_i^2 + b_i x_2)}{b_i^2 + b_i x_3 + x_4} \right]^2$	4	[- 5, 5]	$3e^{-5}$
$F_6(x) = -\sum_{i=1}^4 c_i \exp \left(-\sum_{j=1}^6 a_{ij} (x_j - p_{ij})^2 \right)$	6	[0, 1]	- 3.32

型值 $c_1 = c_2 = 2$, $w_{\text{start}} = 0.9$, $w_{\text{end}} = 0.4$; 在海鸥算法中 u 和 v 为海鸥进行螺旋状运动的相关常数, 和 f_c 共同控制海鸥的位置, 实验中取常用值 $u = 1$, $v = 1$, $f_c = 2$ 。图 1 给出了在六个测试函数中不同算法的收敛曲线。

从图 1 可以看出, MGPALO 算法在六个测试函数的收敛过程中均具有较为明显的优越性。通过在位置更新过程中加入扰动因子, 对部分个体进行高斯差分变异, 有助于算法跳出局部最优, 寻优值更加接近理论最优值。三类测试函数所得到的结果可以看出: MGPALO 算法在对比算法之中, 具有最优的收敛精度和收敛速度。将实验次

数设置为 50, 通过对比各算法进行 50 次独立实验得到的适应度均值和方差参数, 评价各算法的性能。表 2 给出了测试结果。

从表 2 可以看出, 对比各算法在不同测试函数上的寻优均值, MGPALO 算法的收敛精度具有明显优势, 对于六个测试函数, MGPALO 算法寻得的最优值都更加接近理论最优值。另外, GMALO 算法所得到的方差都小于其他对比算法, 即稳定性更优。综合得出: MGPALO 算法对于单峰函数和多峰函数都有较好的适应性, 有效克服了标准蚁狮算法收敛速度慢, 易陷入局部最优的缺点。

表 2 不同算法的寻优结果
Table 2 Optimization results of different algorithms

测试函数	SOA		PSO		ALO		MGPALO	
	均值	标准差	均值	标准差	均值	标准差	均值	标准差
F_1	1.03E+4	4.98E+3	83.10	34.32	4.32E+3	1.55E+3	6.98E-2	0.10
F_2	16.94	14.62	1.07	0.19	17.77	4.81	3.82E-3	3.72E-3
F_3	20.02	3.68E-2	2.25E-2	2.44E-2	5.43	2.95	1.07E-4	1.74E-5
F_4	0.46	0.85	2.28	1.95	15.57	8.50	1.08E-2	2.90E-3
F_5	9.69E-4	3.08E-4	8.70E-4	2.96E-4	3.78E-3	6.82E-3	6.22E-4	1.24E-4
F_6	-3.10	0.11	-3.25	5.82E-2	-3.28	4.79E-2	-3.31	1.63E-3

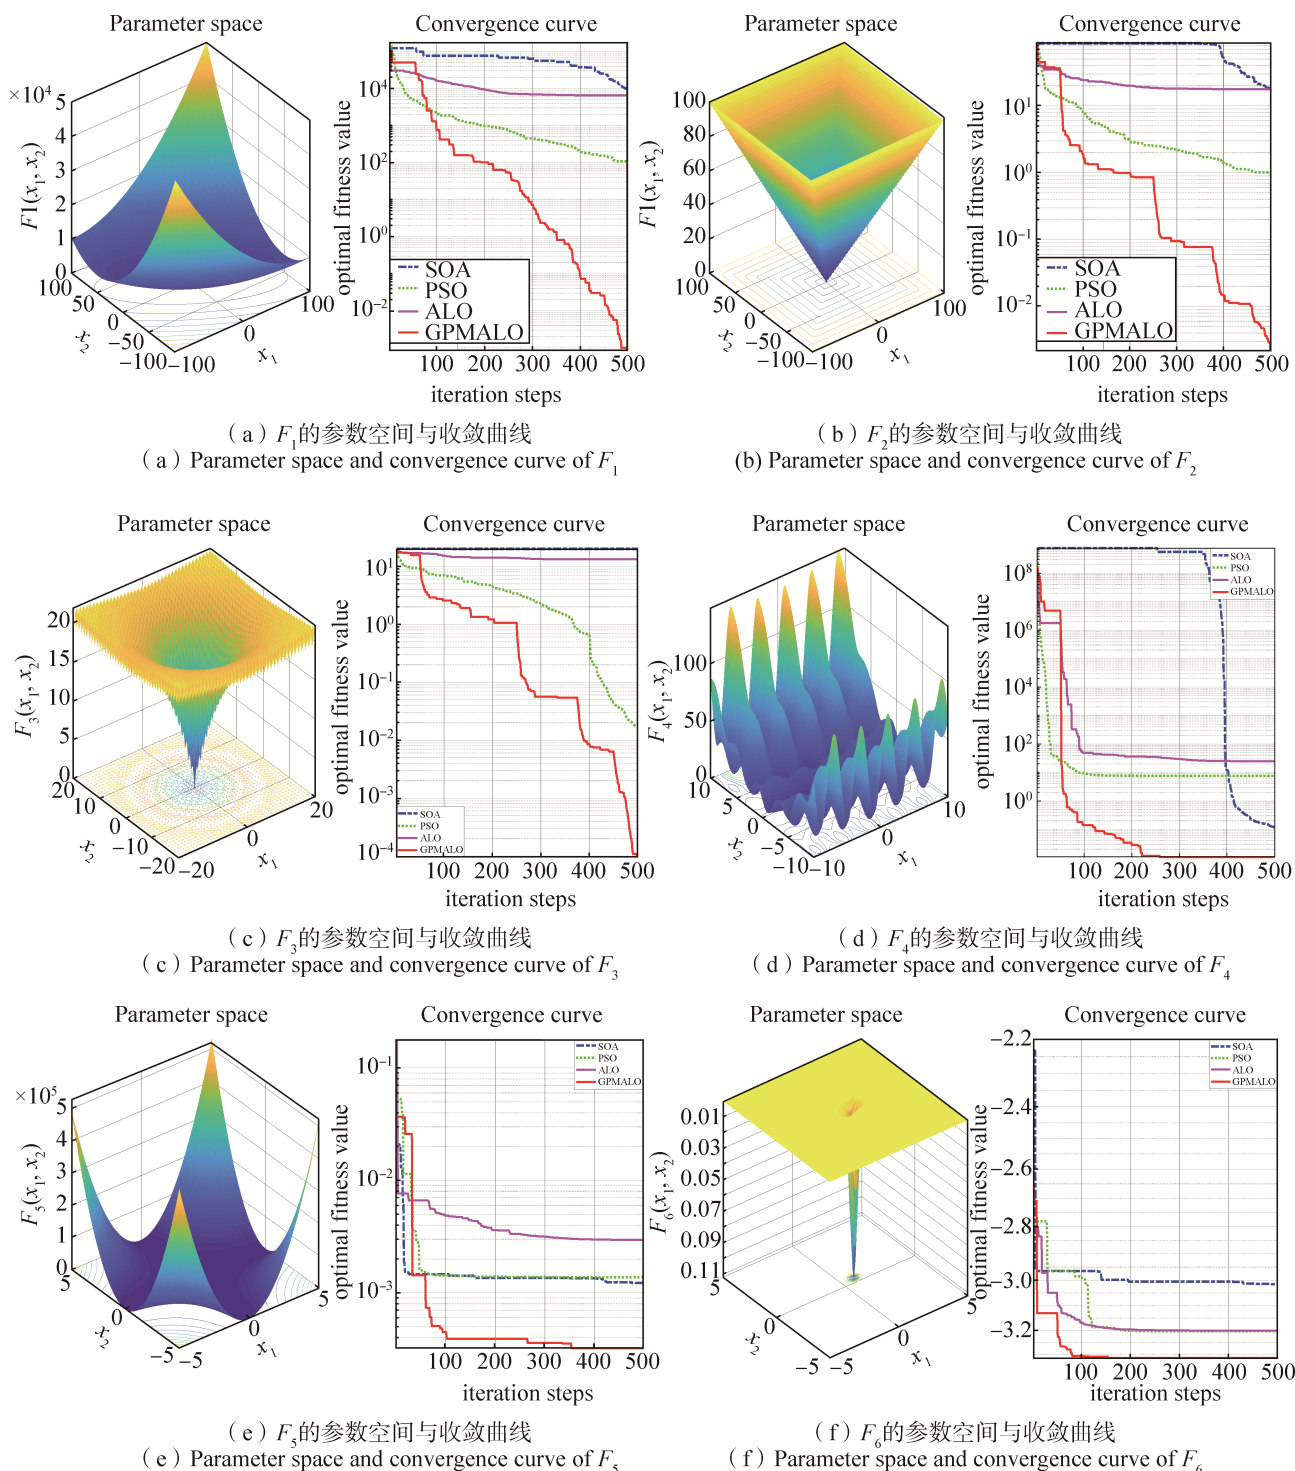


图 1 测试函数的收敛过程

Fig. 1 Convergence process of the test function

4 MGPALO-RBF 模型用于海杂波预测

4.1 海杂波预测模型的建立

由于海杂波具有混沌特性，通过电磁波回波的形式展示了影响海浪形成的多种变量之间相互

作用的内在动力学特性。通常采集到的海杂波为单变量的时间序列，从几何学角度来看，混沌的时间序列就是高维的混沌运动在低维空间上的映射。要从混沌时间序列中研究原来的非线性动力学性态，分析系统中所有状态量所包含的信息，

就需要将单维时间序列经过相空间重构扩展至高维的空间中。由式(10)重构相空间

$$Y(i)=[x_i, x_{i+\tau}, x_{i+2\tau}, \dots, x_{i+(m-1)\tau}] \quad (10)$$

式中, m 和 τ 为相空间重构参数, m 是嵌入维数, τ 是时间延迟, x_i 为单维时间序列上的点, $Y(i)$ 为高维空间中的相点。用微分方程描述海杂波的动力学系统

$$Y(i+1)=\phi(Y(i)) \quad (11)$$

式中, ϕ 是一个非线性函数, 代入重构相空间中点的坐标, 可以得到海杂波的预测方程, 即存在非线性函数 f , 使得

$$x_{i+m\tau}=f(x_i, x_{i+\tau}, \dots, x_{i+(m-1)\tau}) \quad (12)$$

为使方程更具有概括力, 更加精确地获得蕴藏在嵌入空间中的信息, S.Haykin 将海杂波的预测方程进行改进^[18]

$$x_{i+m\tau}=f(x_i, x_{i+1}, x_{i+2}, \dots, x_{i+(m-1)\tau}) \quad (13)$$

为得到海杂波预测方程的表达式, 对径向基神经网络进行训练学习, 将神经网络作为一个函数估计器, 尽可能地逼近函数 f , 从而拟合海杂波非线性输入输出的映射关系。

在 RBF 神经网络模型中, 本文所使用的径向基函数为高斯核函数, 由式(14)定义

$$G(x_i, c_j)=\exp\left(-\frac{\|x_i-c_j\|^2}{2\sigma_j^2}\right) \quad (14)$$

式中, x_i 表示神经网络的输入变量, 维数是 $m \cdot \tau$ 。 c_j 表示第 j 个径向基函数的 $m \cdot \tau$ 维数据中心, σ_j 表示第 j 个径向基函数的扩展常数。

设计 RBF 神经网络模型的关键在于两个方面: 一是结构设计, 即确定输入层、隐含层、输出层的节点数目; 二是参数设计, 即选取径向基函数的数据中心、扩展常数及隐含层与输出层间的权值参数。由于这三类参数的选择会影响神经网络模型的预测结果, 为了提高模型的总体预测性能, 保证神经网络的初始化参数的选取为最优值, 本文引入蚁狮算法并加以改进, 采用改进蚁狮算法优化海杂波预测模型。

基于 MGPALO 的海杂波预测模型的建立主要包括如下步骤:

① 确定 RBF 神经网络的结构;

② 设置蚂蚁和蚁狮的种群规模, 将数据中心 c 、扩展常数 σ 、网络权值 w 这三种待优化的参数映射为蚂蚁和蚁狮个体的位置矢量;

③ 通过改进的蚁狮优化算法在搜索空间中进行寻优, 根据适应度值进行评估, 将得到的精英蚁狮的位置矢量还原为所对应的网络参数的初始化值; 适应度值由式(15)定义

$$f_{\text{Fitness}}=\frac{\sum_{i=1}^N(y_i-\hat{y}_i)^2}{N} \quad (15)$$

式中, N 为训练样本个数, y 为实际输出值, \hat{y} 为预测值。

④ 将雷达回波信号通过奇异值分解方法去除地物杂波, 并进行归一化处理、相空间重构等操作, 构造训练数据和预测数据;

⑤ 设置神经网络的期望精度及最大训练次数, 将海杂波训练数据用于网络模型的训练学习, 通过梯度算法^[19]不断调整网络参数, 最终得到 MGP-ALO-RBF 神经网络模型;

⑥ 将得到的神经网络模型用于海杂波预测。

在模型的建立过程中, 通过平均补偿率对径向基神经网络的预测精度进行评估, 平均补偿率由式(16)定义

$$\gamma=1-\frac{\text{var}(e_i)}{\text{var}(Y_i)}=1-\frac{\sum_{i=1}^N(e_i-\bar{e}_i)^2}{\sum_{i=1}^N(Y_i-\bar{Y}_i)^2} \quad (16)$$

式中, var 表示取方差, e_i 表示输出值与真实值间的误差, \bar{e}_i 为误差取均值, Y_i 表示海杂波的观测值, \bar{Y}_i 为海杂波的观测值取均值。平均补偿率越大则预测精度越高。

4.2 实验结果及分析

实验所用数据为工作频率是 3.7 MHz、采样间隔是 0.149 s 的威海高频地波雷达的实测数据。接收数据分为 I(实部)通道和 Q(虚部)通道。由第 31 个距离单元的回波数据构造训练数据, 由第 30 个距离单元的回波数据构造测试数据。

对于神经网络模型的结构设计而言, 输入层的节点个数即网络单个输入样本的维度, 等于 m (嵌入维数) 和 τ (时间延迟) 的乘积, 由 C-C 算法^[20]得到, $m=3, \tau=4$, 因此输入层的神经元节点个数为 12。隐含层的节点个数根据实际问题进行调整, 通过实验观察得到: 当隐含层节点数为 4~8 时, 网络模型的训练精度最高。为减少计算量, 本文中隐含层神经元的节点数为 4。输出层的节点数为网络预测结果的维度, 设置为 1。神经网络的初始化

参数则通过优化算法进行寻优后赋值。PSO算法中 $c_1=c_2=2$, $w_{start}=0.9$, $w_{end}=0.4$, SOA算法中 $u=1$, $v=1$, $f_c=2$, 均设置为常用典型值。不同优化算法均在种群数量为30, 最大迭代次数为300的同一条件下进行仿真, 各优化算法所得适应度值的收敛曲线由图2给出。

从图2仿真结果可以看出: 海鸥算法和粒子群算法多次僵持在局部最优状态难以突破。对比于PSO和SOA, 标准蚁狮算法的收敛速度更快并且精度更高。而本文MGPALO算法相比于原算法具有更强的开发能力, 更高的收敛精度, 在几种算法中性能表现最优。

各优化算法中种群的初始化位置均随机产生, 种群不同的空间分布会导致寻优结果不同。为了更加客观的评价各个优化算法的性能, 采用多次实验取均值的方法对各个模型进行测试。不同优化算法均独立运行40次, 训练次数设置为1000, 期望精度为0.01。将得到的预测模型用于第30个

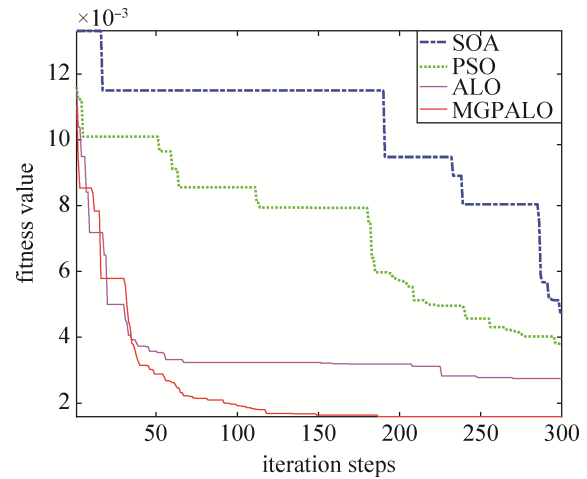


图2 适应度值收敛曲线

Fig 2 Convergence curve of fitness value

距离单元上海杂波的预测, 实验结果由表3给出。表3分别给出了未经优化的神经网络模型以及由海鸥算法、粒子群算法、标准蚁狮算法、改进蚁狮算法优化的神经网络模型的仿真结果。

表3 海杂波预测效果

Table 3 Prediction effect of sea clutter

模型	数据类型	适应度均值	适应度标准差	预测精度(%)
RBF	实部	--	--	84.24
	虚部	--	--	86.18
SOA-RBF	实部	6.28E-3	1.04E-3	93.12
	虚部	6.18E-3	2.10E-3	93.71
PSO-RBF	实部	2.94E-3	1.71E-3	93.86
	虚部	2.39E-3	8.15E-4	94.53
ALO-RBF	实部	2.76E-3	5.81E-4	94.03
	虚部	2.46E-3	6.38E-4	94.61
MGPALO-RBF	实部	1.77E-3	3.81E-4	95.90
	虚部	1.84E-3	2.53E-4	96.03

从表3可以看出: 未经优化的神经网络模型预测效果不佳, 这是由于该模型是通过随机产生初始化值的方式进行参数设计, 这种随机性导致了网络模型的稳定性较差。优化算法帮助寻找更优的网络初始化参数, 在一定程度上提高了模型的稳定性及预测精度。本文提出的MGPALO优化算法无论是在实部数据还是虚部数据的处理上所得到的适应度均值都是最低, 并且对于临近距离单元的海杂波预测精度都最高, 这表示该模型中优化算法所得到的网络初始化参数为最优。另外, 由各优化算法所得的适应度标准差可以看出: 改

进蚁狮算法所得到的适应度标准差值最低, 说明该模型的稳定性更优。相比于其他模型, MGPALO-RBF神经网络模型的总体性能最佳。

MGPALO-RBF模型用于对30个距离单元的海杂波进行预测, 图3分别给出了海杂波实部和虚部的预测结果。从仿真结果中可以看出, 海杂波的预测值与观测值具有较高的吻合度, MGPALO-RBF模型具有较好的海杂波预测性能。

5 结束语

本文在基本蚁狮算法的基础上进行改进, 并

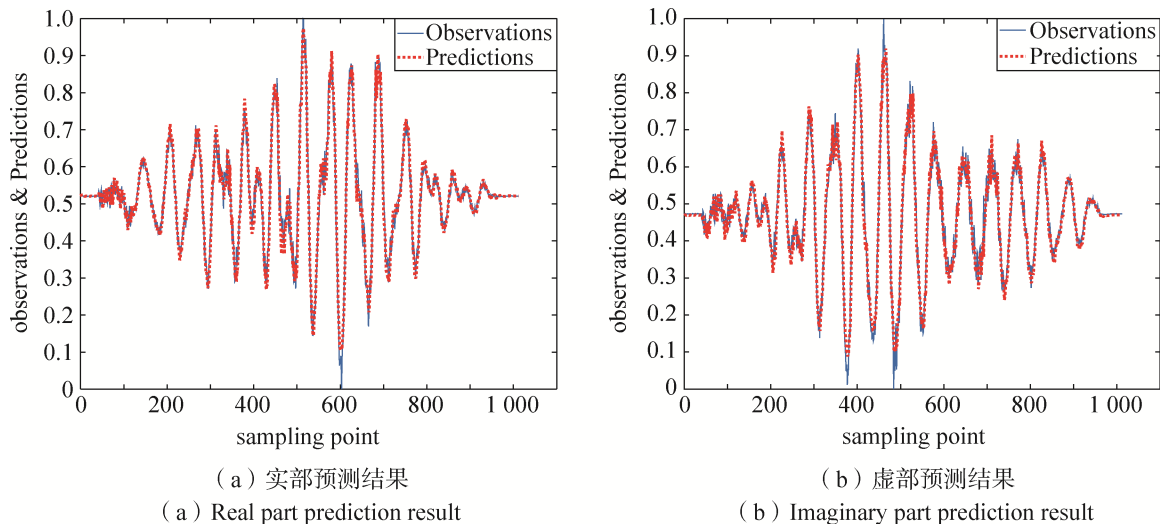


图3 海杂波实部和虚部预测结果

Fig.3 Prediction results of real and imaginary parts of sea clutter

采用改进蚁狮算法优化RBF神经网络。通过在随机游走公式中加入扰动因子、引入多个精英蚁狮个体动态引导蚂蚁进行位置更新、对种群中较差蚁狮进行高斯差分变异操作,充分提高了优化算法的总体性能。利用标准测试函数对几种算法进行评估,仿真结果表明:改进后的蚁狮算法具有更高的收敛精度及稳定性。

将改进蚁狮算法用于优化RBF神经网络模型,利用模型学习海杂波的内在动力学特性。对于第30个距离单元的海杂波实部数据进行预测,MGPALO-RBF模型较RBF模型和ALO-RBF模型的预测精度分别提高了11.66%和1.87%;对于第30个距离单元的海杂波虚部数据进行预测,MGPALO-RBF模型较RBF模型和ALO-RBF模型的预测精度分别提高了9.85%和1.42%。MGALO-RBF模型在对比模型中的预测精度最高,对于海杂波抑制和目标检测具有重要意义。

参考文献

- [1] 王瑞富,孔祥超,纪永刚,等.基于GIS的高频地波雷达回波信号的表达处理与显示[J].海洋科学,2015,39(7): 86-92.
WANG Furui, KONG Xiangchao, JI Yonggang, et al. Expression and display of echo signal of HF surface wave radar based on GIS[J]. Marine Sciences, 2015, 39 (7): 86-92.
- [2] 何康宁,尚尚.高频地波雷达海杂波抑制方法研究综述[J].遥测遥控,2019,40(4): 10-16.
HE Kangning, SHANG Shang. Review on sea clutter suppression methods of high frequency surface wave radar[J]. Journal of Telemetry, Tracking and Command, 2019, 40(4): 10-16.
- [3] SIMON R A, KUMAR P B V. A nonlinear sea clutter analysis using chaotic system[C]//2013 Fourth International Conference on Computing, Communications and Networking Technologies (ICCCNT). IEEE, 2013: 1-5.
- [4] 何康宁.基于RBF神经网络的高频地波雷达海杂波抑制方法研究[D].江苏科技大学,2021.
- [5] 雒贤华,王智勇,王大语,等.基于ACO-RBF神经网络的接触电阻预测[J].传感器与微系统,2021,40(11): 139-142.
LUO Xianhua, WANG Zhiyong, WANG Dayu, et al. Prediction of contact resistance based on ACO-RBF neural network[J]. Transducer and Microsystem Technologies, 2021, 40(11): 139-142.
- [6] 张小青,吴继侠,唐榕蔚.基于灰狼优化算法的RBF神经网络[J].信息技术与信息化,2021(9): 26-28.
- [7] MIRJALILI S. The ant lion optimizer[J]. Advances in engineering software, 2015, 83: 80-98.
- [8] PETROVIĆ M, PETRONIJEVIĆ J, MITIĆ M, et al. The ant lion optimization algorithm for integrated process planning and scheduling[C]//Applied Mechanics and Materials. Trans Tech Publications Ltd, 2016, 834: 187-192.
- [9] AZIZI M, GHASEMI S A M, EIJALI R G, et al. Optimum design of fuzzy controller using hybrid ant lion optimizer and Jaya algorithm[J]. Artificial Intelligence Review, 2020, 53(3): 1553-1584.
- [10] 王茜,何庆,林杰,等.精英反向学习带扰动因子的混

- 沌蚁狮算法[J]. 智能计算机与应用, 2020, 10(8): 51-57.
- WANG Qian, HE Qing, LIN Jie, et al. Chaos ant lion optimizer based on elite opposition—based learning with perturbation factor[J]. Intelligent Computer and Applications, 2020, 10(8): 51-57.
- [11] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer [J]. Advances in Engineering Software, 2014, 69(7): 46-61.
- [12] 刘景森, 霍宇, 李煜. 优选策略的自适应蚁狮优化算法[J]. 模式识别与人工智能, 2020, 33(2): 121-132.
- LIU Jingsen, HUO Yu, LI Yu. Preferred strategy based self-adaptive ant lion optimization algorithm[J]. Pattern Recognition and Artificial Intelligence, 2020, 33(2): 121-132.
- [13] 张晓庆, 高尚, 范霁月. 基于混合变异的人工蜂群算法[J]. 江苏科技大学学报(自然科学版), 2018, 32(1): 93-99.
- ZHANG Xiaoqing, GAO Shang, FAN Jiyue. Artificial bee colony algorithm based on hybrid mutation[J]. Journal of Jiangsu University of Science and Technology (Natural Science Edition), 2018, 32(1): 93-99.
- [14] SHI Y, EBERHART R. A modified particle swarm optimizer[C]//1998 IEEE International Conference on Evolutionary Computation Proceedings. IEEE World Congress on Computational Intelligence (Cat. No. 98TH-8360. IEEE, 1998: 69-73.
- [15] DHIMAN G, KUMAR V. Seagull optimization algorithm: Theory and its applications for large-scale industrial engineering problems[J]. Knowledge-Based Systems, 2019, 165: 169-196.
- [16] 潘赢, 贾国庆, 郜伟伟. SOA优化BP神经网络的水体氨氮预测模型[J]. 佳木斯大学学报(自然科学版), 2020, 38(2): 40-44.
- PAN Ying, JIANG Guoqing, GAO Weiwei. Prediction model of ammonia nitrogen in water based on SOA optimized BP neural network[J]. Journal of Jiamusi University(Natural Science Edition), 2020, 38(2): 40-44.
- [17] 许乐, 莫愿斌, 卢彦越. 基于改进海鸥优化算法的PID控制器参数优化[J]. 机床与液压, 2021, 49(16): 17-23.
- XU Le, MO Yuanbin, LU Yanyue. Parameter optimization of PID controller based on improved seagull optimization algorithm[J]. Machine Tool & Hydraulics, 2021, 49(16): 17-23.
- [18] HAYKIN S. Radar clutter attractor: Implications for physics, signal processing and control[J]. IEE Proceedings Radar Sonar & Navigation, 1999, 146(4): 177-188.
- [19] CHEN S, CHNG E S, ALKADHIMI K. Orthogonal least squares learning algorithm for radial basis function networks[J]. IEEE Trans Neural Netw, 1991, 64(5): 829-837.
- [20] KIM H S, EYKHOLT R, SALAS J D. Nonlinear dynamics, delay times, and embedding windows[J]. Physica D: Nonlinear Phenomena, 1999, 127(1-2): 48-60.

[作者简介]

张先芝 1998年生, 硕士研究生, 主要研究方向为弱目标检测与海杂波抑制。

尚 尚 1982年生, 副教授, 硕士生导师, 主要研究方向为雷达信号处理与杂波抑制方法研究。

戴圆强 1997年生, 硕士研究生, 主要研究方向为弱目标检测与电离层杂波抑制。

杨 童 1997年生, 硕士, 主要研究方向为高频地波雷达信号处理和目标检测。

刘 明 1997年生, 硕士研究生, 主要研究方向为信号预测。

(本文编辑: 傅 杰)