

文章编号: 1673-3193(2021)02-0177-10

基于 SCAGOA 优化 BP 神经网络和 极大似然算法的 DOA 估计研究

陈 婷, 燕慧超, 王 鹏, 谭秀辉, 白艳萍

(中北大学 理学院, 山西 太原 030051)

摘 要: 利用 BP 神经网络和极大似然(ML)算法对阵列信号波达方向(DOA)进行估计, 结合了混沌映射和群智能优化算法的优势, 设计了一种正余混沌双弦蝗虫优化算法(SCAGOA), 不仅解决了因神经网络的权值和阈值选取不当导致陷入局部最优的问题, 而且解决了 ML 算法中多维搜索导致运算负荷大、效率低的问题。通过仿真实验对双信号源的输出效果和估计误差进行讨论, 比较了不同优化算法对信噪比的泛化能力。结果表明, 通过 SCAGOA 优化后的 BP 神经网络和 ML 算法在 DOA 估计方面比其他优化算法具有更好的估计精度。

关键词: 神经网络; 极大似然估计; 蝗虫优化算法; 正余弦优化算法; 阵列信号; DOA 估计

中图分类号: TN911.7

文献标识码: A

doi: 10.3969/j.issn.1673-3193.2021.02.015

Research on DOA Estimation Based on SCAGOA Optimized BP Neural Network and Maximum Likelihood Algorithm

CHEN Ting, YAN Hui-chao, WANG Peng, TAN Xiu-hui, BAI Yan-ping

(School of Science, North University of China, Taiyuan 030051, China)

Abstract: The direction of arrival (DOA) of array signal is estimated by using BP neural network and maximum likelihood estimation (ML). We combined the advantages of chaos mapping and swarm intelligence optimization algorithm to design a sines cosine chaotic double string grasshopper optimization algorithm (SCAGOA). On the one hand, it can solve the problem of falling into local optimum due to improper selection of weights and thresholds of neural network; on the other hand, it can solve the problem of computational load and low efficiency caused by multidimensional search in maximum likelihood. The output effect and estimation error of two signal sources were discussed through simulation experiments. The generalization ability of different optimization algorithms to SNR were compared. The results show that the optimized BP neural network and maximum likelihood method have better estimation accuracy than other optimization algorithms in DOA estimation.

Key words: neural network; maximum likelihood(ML) estimation; grasshopper optimization algorithm; sines and cosines optimization algorithm; array signal; DOA estimation

0 引 言

海洋资源非常丰富, 开发海洋资源, 破解海洋

信息已成为众多专家学者的研究方向。水声信号是
破解海洋信息的关键, 属于阵列信号的研究内容。
根据信号在空间各个方向上的能量分布, 得到信号

收稿日期: 2020-09-15

基金项目: 国家自然科学基金资助项目(61774137); 山西省自然科学基金资助项目(201801D121026, 201701D221121); 山西省回国留学人员科研资助项目(2020-104, 2016-088); 山西省重点研发计划资助项目(201903D121156); 中北大学 2017 年校科研基金资助项目(2017027)

作者简介: 陈 婷(1994—), 女, 硕士生, 主要从事阵列信号处理及优化算法的研究。

的空间谱,就能得到信号的波达方向,常被称为 DOA 估计^[1]. 自 20 世纪 70 年代末开始,由 Schmidt R O 等提出的子空间类方法——多重分类信号(MUSIC)算法^[2-4],在 DOA 估计方面实现了向现代超分辨测向技术的飞跃.其主要对阵列的输入数据进行奇异值分解或特征分解以获得信号子空间和噪声子空间,并利用两个子空间的正交性构造“针状”空间谱峰,该算法具有很好的角度分辨能力,但是运算量偏大.另一类重要方法是以旋转不变子空间(ESPRIT)为代表的子空间类算法^[5-6],利用信号子空间的旋转不变特性进行 DOA 估计,能够避免运算量极大的谱搜索过程,但需要通过特殊的阵列结构才能实现,适用范围相对较窄.20 世纪 80 年代后期,又出现了一类子空间拟合类算法,比较有代表性的有极大似然(ML)算法^[7-8]、加权子空间拟合(WSF)算法^[9]等.其中 ML 算法中由于方向估计似然函数是非线性的,求解其最优解需多维搜索,运算量巨大,但是与子空间分类算法(如 MUSIC, ESPRIT)相比,在低信噪比、小快拍数据情况下,其性能要好很多.近几十年来,神经网络被广泛应用于工程应用中,基于神经网络的 DOA 估计无需进行特征值分解以及谱峰搜索,计算时间大大降低,比较具有代表性的人工神经网络包括 BP 神经网络^[10]、RBF 神经网络^[11]和 GRNN 神经网络^[12]等.

近些年,随着智能优化算法的不断提出,不少学者将这些启发式算法与传统 DOA 估计方法相结合,对联合后的算法适当改进,旨在利用智能优化算法的优势去避免或改善原有方法的一些限制和不足,保证预估角度的准确性.本文选用改进的蝗虫优化算法(GOA)对 BP 神经网络和 ML 算法进行优化. GOA 算法^[13-14]源于对大自然中蝗虫群体的捕食行为的模拟,不仅通过其当前的位置和全局最好的位置更新位置,而且还通过

$$X_i^d(t+1) = c \left\{ \sum c \cdot \frac{ub_d - lb_d}{2} \cdot s(|X_j^d(tj) - X_i^d(t)|) \cdot \frac{x_j(t) - x_i(t)}{d_{ij}} \right\} + T_d, \quad (2)$$

式中: lb_d 为上边界; ub_d 为下边界; T_d 为当前最优解; $s(\cdot)$ 定义为一个函数,表示蝗虫间的社会作用力

$$s(d) = fe^{-\frac{d}{l}} - e^{-d}, \quad (3)$$

式中: f 为吸引力强度; l 为有吸引力的大小范围,本文中 $l=1.5$, $f=0.5$. 如图 1 所示,当函数 $s(\cdot)$ 中 $l=1.5$, $f=0.5$ 时,为了避免远距离 $s(d)$ 为零的问题,需要将 x 映射到 $[1,4]$ 之间.

其他蝗虫的位置更新位置,要求所有个体都参与到优化过程中,搜索效率更高,但是存在陷入局部极值的问题.因此,在其中引入正余弦混沌映射(SCA)^[15-17],在每一次群优化算法迭代初步寻找到最优解后,进一步混沌迭代寻优,相当于在当前最优解周围搜索多个具有混沌特性的点,这样能够很好地结合各自算法的特点.

通过大量仿真实验可以得知,利用正余混沌双弦蝗虫优化算法(SCAGOA)优化后的 BP 神经网络的权值和阈值进行 DOA 估计时,能够弥补选取不当陷入局部最小的不足,从而在精确度和对信噪比的泛化能力有明显的改善;利用 SCAGOA 优化 ML 算法进行 DOA 估计时,借鉴了蝗虫之间的位置更新行为,对极大似然函数进行搜索,避免了 ML 算法估计来波方向的寻优盲点.

1 本文算法

1.1 正余混沌双弦蝗虫优化算法(SCAGOA)

1) 初始化参数: N , Max_iter , C_{max} , C_{min} , ub , lb 和 dim .

其中, N 为种群个数; Max_iter 为最大迭代次数; C_{max} , C_{min} 用来计算求解 c 的最值范围; lb , ub 为计算蝗虫间距离的上下边界值; dim 为维数.

2) 初始化种群. 根据适应度函数计算种群中每个蝗虫的目标函数值,按照目标函数值的大小进行排序,找出初始种群中的最优个体蝗虫.

3) 开始循环,参数 $c(\cdot)$ 为缩小系数,用来线性减少舒适空间、排斥空间和吸引空间. 利用下式求解 c

$$c(t) = C_{max} - t \frac{C_{max} - C_{min}}{t_{max}}, \quad (1)$$

对于每一个搜索个体,计算当前蝗虫与最优蝗虫的距离. 利用下式更新当前个体位置

$$X_i = \sum_{\substack{j=1 \\ j \neq i}}^N s(|X_j - X_t|) \frac{x_j - x_t}{d_{ij}} - ge_g + ue_w, \quad (4)$$

式中: u 为空气漂移常量; e_w 为与风力方向相同的单位矢量,幼年的蝗虫没有翅膀,因此,它们的主要动力来源为风对蝗虫的作用力; N 为蝗虫的数量.

4) 种群中个体容易在解空间内迅速聚集在一

起,群体多样性迅速衰落,增大陷入局部最优的几率,因此,引入正余混沌机制来控制种群个体的运动区域.利用下式对当前个体的位置进行正余双弦混沌映射

$$X_{ij}^{t+1} = \begin{cases} X_{ij}^t + r_1 \cdot \sin(r_2) \cdot |r_3 P_{gj}^t - X_{ij}^t|, & r_4 < 0.5, \\ X_{ij}^t + r_1 \cdot \cos(r_2) \cdot |r_3 P_{gj}^t - X_{ij}^t|, & r_4 \geq 0.5, \end{cases} \quad (5)$$

式中: x_{ij}^t 为第 t 次迭代中第 i 个粒子在第 j 维搜索空间中的位置; P_{gj}^t 为种群的全局极值; r_1 为线性

递减函数,控制正余弦全局搜索的区域范围,

$$r_1 = a - t \cdot \frac{a}{T}, \quad (6)$$

式中: $a=2$; t 为当前迭代次数; T 为最大迭代次数; r_1 随着迭代次数的增加会自适应减少,缩小寻优范围,保证算法收敛性; r_2 为范围在 $[0, 2\pi]$ 的随机数,主要增加种群位置的均衡遍历性; r_3 为范围在 $[-2, 2]$ 的随机数; r_4 为范围在 $[-1, 1]$ 的随机数,对当前个体位置进行调整,自适应调整变异程度.




图 1 当函数 $s(\cdot)$ 中 $l=1.5$, $f=0.5$ 时, x 范围在 $[1, 4]$ 之间

Fig. 1 x is in $[1, 4]$ when $l=1.5$ and $f=0.5$ in function s

在得到当前最优个体附近的具有混沌特性的搜索点后,将这些搜索点代入到目标函数中进行计算,与当前最优个体进行比较,如果目标函数值优于当前最优个体的函数值,则进行位置更新.

5) 重新安置超过搜索边界的个体,计算所有个体的目标函数值,直至达到最大循环次数.

6) 判断 t 是否达到 Max_iter ,若是,则算法结束,同时输出 $T_arg_etposition$ 和 $T_arg_etfitness$;若不是,令 $t=t+1$,转向步骤 3)继续执行.

1.2 基于 SCAGOA 优化 BP 神经网络的 DOA 估计

利用传统 BP 神经网络进行 DOA 估计时,往往会因为 BP 神经网络的权值和阈值选取不当,导致陷入局部最优,所以,利用 SCAGOA 优化方法对 BP 神经网络的权值和阈值进行选取,这样能有

效地在全局范围内找到最优值.

主要流程如下:

根据蝗虫种群中成虫大范围搜索和幼虫小范围移动,并整体向最终食物源位置移动的方式,实现位置优化,这种寻找食物源的活动被认为是寻优过程,用式(2)来模拟个体间的相互作用,将每一个蝗虫位置映射为解,代入到适应度函数中进行计算和比较,当达到适应度值最大或者迭代次数满足最大时,更新结束,将全局最优个体的位置坐标对应到 BP 神经网络结构中的权值和阈值上.将接收到的阵列信号进行处理,求解协方差矩阵、实值化并特征分解,得到关于接收信号的信号子空间,选取信号子空间的基作为 BP 神经网络的输入,经过 BP 神经网络训练,建立 DOA 估计预测模型.具体流程图如图 2 所示.




图 2 基于 SCAGOA 优化 BP 神经网络的 DOA 估计算法流程图

Fig. 2 Flow chart of DOA estimation algorithm based on SCAGOA optimized BP neural network

1.3 基于 SCAGOA 优化 ML 算法的 DOA 估计

在 ML 算法中, 所得信号的似然函数被定义为含有未知参数的条件概率密度函数, 通过选定未知的参数使得似然函数最大化. 主要思想是

ML 算法中的谱函数对应为种群优化中的适应度函数, 把似然函数看做目标, 用来计算适应度值, 并将其作为评判个体位置优劣的标准, 适应值对应的解向量就是待估计方向角的可行解. 具体流程图见图 3.




图 3 基于 SCAGOA 优化 ML 算法的 DOA 估计算法流程图

Fig. 3 Flow chart of DOA estimation algorithm based on SCAGOA optimized ML algorithm

2 DOA 估计

2.1 基于 SCAGOA 优化 BP 神经网络的 DOA 估计

2.1.1 仿真实验

本文通过 MATLAB 仿真验证所提算法的可行性. 仿真条件: 均匀的 5 元天线阵列, 两个非相干的正弦信号作为信号源, 信噪比为 10 dB, 快拍数为 1 000, 阵元间距为 0.5. 训练样本: 信号源之间的间隔分别取 12° 和 18° , 在 $-90^\circ \sim 90^\circ$ 内每隔 0.5° 取 1 个样本, 总共产生 722 个样本作为训练样本. 测试样本: 信号源之间的间隔取 15° , 从 $-90^\circ \sim 90^\circ$ 内每隔 1° 取 1 个样本, 共产生 181 个样本作为测试样本. 进行 100 次 Monte-Carlo 仿真实验.

本文利用 BP 神经网络、GOA-BP 神经网络和 SCAGOA-BP 神经网络进行 DOA 估计, 得到信号的输出估计误差曲线, 如图 4 所示.

由图 4 可以看出, 3 种方法的输出预测角度误差基本都控制在 $\pm 2^\circ$ 以内, GOA-BP 神经网络

和 BP 神经网络都有信息突变, 造成误差较大, 而 SCAGOA-BP 神经网络的输出预测角度误差介于 GOA-BP 神经网络和 BP 神经网络的输出预测角度误差之间, 在零附近震荡, 预测值更加接近实际值.

表 1 所示为基于 SCAGOA-BP 神经网络的输出估计成功概率, 由表 1 可知, 在 100 次仿真实验中, 无论是信号 1 还是信号 2, 本文所提的 SCAGOA-BP 神经网络下的 DOA 估计的成功概率更高, 说明该改进智能优化算法提高了全局搜索能力, 避免陷入局部最优.

表 1 基于 SCAGOA-BP 方法的输出估计成功概率

Tab. 1 Success probability of output estimation based on SCAGOA-BP method

算法	信号 1 成功概率/%	信号 2 成功概率/%
BP	88.39	80.11
GOA-BP	88.39	78.45
SCAGOA-BP	91.16	86.74




图 4 基于 SCAGOA-BP 方法的输出估计误差曲线

Fig. 4 Output estimation error curve based on SCAGOA-BP method

2.1.2 算法比较

在两个信号源 DOA 估计的仿真条件基础上, 本节选用均方误差(MSE)、均方根误差(RMSE)和平均绝对误差(MAE)作为衡量算法的指标, 分

别将 BP 神经网络、灰狼优化 BP 神经网络(GWO-BP)、粒子群优化 BP 神经网络(PSO-BP)、GOA-BP 神经网络和 SCAGOA-BP 神经网络 MSE 值、RMSE 值和 MAE 值进行对比, 结果见表 2.

表 2 五种神经网络下的 DOA 估计误差

Tab. 2 DOA estimation errors under five neural networks

算法	MSE1/(°) ²	RMSE1/(°)	MAE1/(°)	MSE2/(°) ²	RMSE2/(°)	MAE2/(°)
BP	0.366 9	0.605 8	0.454 2	0.406 7	0.637 7	0.522 3
GWO-BP	0.334 7	0.578 5	0.426 4	0.310 4	0.557 2	0.442 6
PSO-BP	0.266 9	0.516 6	0.396 3	0.236 9	0.486 7	0.377 9
GOA-BP	0.317 1	0.563 1	0.407 7	0.468 1	0.684 2	0.516 1
SCAGOA-BP	0.212 8	0.461 3	0.370 6	0.243 4	0.493 3	0.390 9

通过表 2 数据可以看出, 对于信号源 1, SCAGOA-BP 神经网络比 BP 神经网络、GWO-BP 神经网络、PSO-BP 神经网络和 GOA-BP 神经网络 DOA 估计的 MSE、RMSE 和 MAE 值都小; 对于信号源 2, 除 PSO-BP 神经网络效果略优于 SCAGOA-BP 神经网络外, 其余优化后的神经网络 DOA 估计效果都稍差一些. 通过对每种优化方法运行 10 次计算其运行时间发现, GWO-BP 神经网络和 GOA-BP 神经网络耗时在 200 s~250 s 以内, PSO-BP 神经网络耗时在 450 s~500 s 内, 而本文所提的 SCAGOA-BP 神经网络耗时在 60 s~100 s 内. 整体来说, SCAGOA-BP 神经网络在 DOA 估计方面拟合优度更好, 在训练时间较短的情况下也能保证估计的精度更准确.

2.1.3 不同信噪比下的 RMSE

在上述实验的前提下, 将信噪比依次定为 -10 dB、-5 dB、0 dB、5 dB、10 dB、15 dB, 进行 DOA 估计, 将双信号源的 RMSE 进行记录, 如

图 5 所示, 求取双信号源的 RMSE 的平均值进行统计, 见表 3.




图 5 不同优化算法对信噪比的泛化能力

Fig. 5 Generalization ability of different optimization algorithms to SNR

通过图 5 和表 3 可知, 在信噪比 -10 dB~15 dB 内, 各类神经网络下进行 DOA 估计的 RMSE 值都随着信噪比的增加逐渐减小, 同时

SCAGOA-BP 神经网络的 RMSE 值比 BP 神经网络、GWO-BP 神经网络、PSO-BP 神经网络和 GOA-BP 神经网络的小,可见 SCAGOA-BP 神经网络对于信噪比的泛化能力更强。

表 3 不同信噪比下的各算法的 RMSE
Tab. 3 RMSE under different SNR in different algorithms

算法	-10 dB	-5 dB	0 dB	5 dB	10 dB	15 dB
BP	2.124 5	1.146 0	0.832 6	0.648 5	0.621 8	0.425 2
GWO-BP	2.204 7	1.186 9	0.769 1	0.675 9	0.567 8	0.458 6
PSO-BP	2.208 4	1.132 6	0.746 2	0.591 9	0.501 7	0.419 0
GOA-BP	1.842 8	1.141 7	0.758 8	0.734 6	0.623 6	0.405 2
SCAGOA-BP	1.748 2	1.065 1	0.713 2	0.580 5	0.477 3	0.341 0

2.2 基于 SCAGOA 优化 ML 算法的 DOA 估计

2.2.1 仿真实验

仿真条件:阵元数为 5,信源数为 2,信噪比为-15 dB、-10 dB、-5 dB、0 dB、5 dB、10 dB、15 dB,采样点个数为 100,将两个独立的窄带信号通过 $[20^{\circ},40^{\circ}]$ 两个方向入射到阵列中,利用差分极大似然(DE-ML)算法,灰狼极大似然(GWO-ML)算法,蝗虫极大似然(GOA-ML)算法,SCAGOA-ML 算法依次进行矢量水听器的 DOA 估计,迭代 100 次,观察不同信噪比下,基于不同优化算法下 DOA 估计的 RMSE 值。

观察图 6 曲线结果可知,信噪比在-15 dB~15 dB 时,基于 4 种不同优化算法下的 DOA 估计 RMSE 值都大幅度减小,并且趋于平稳,说明优化后的结果使得 DOA 估计效果更加精确,并且 SCAGOA-ML 算法的 DOA 估计 RMSE 曲线在-10 dB~15 dB 之间要低于 DE-ML 算法、GWO-ML 算法、GOA-ML 算法的曲线,可见经过 SCAGOA-ML 算法进行 DOA 估计后的测向精度在逐步增强,测角误差更小,对信噪比的泛化能力更高。




图 6 不同优化算法的 DOA 估计 RMSE 值

Fig. 6 DOA estimation RMSE values under different optimization algorithms

2.2.2 算法比较

表 4 为基于 4 种不同优化算法的估计结果,将两个独立的窄带信号通过入射角度为 $[20^{\circ},40^{\circ}]$ 的两个阵列中,进行 100 次 Monte-Carlo 仿真实验,得到预估角度的均值和 RMSE 值。本文中,将误差角度控制在 2° 内认为预估成功,将成功概率记录后对比不同优化算法下的预估效果。由表 4 得知,SCAGOA-ML 算法预估效果相比 GWO-ML 算法、DE-ML 算法、GOA-ML 算法更加精准,在 100 次 Monte-Carlo 仿真实验中,成功概率更高, RMSE 值更小。本文对每种优化方法小循环 50 次,大循环 10 次,观察其运行时间,DE-ML 算法耗时最长,需要 80 s~100 s, GWO-ML 算法和 GOA-ML 算法需要 30 s~50 s,而本文提出的 SCAGOA-ML 算法仅需 10 s 左右,这说明通过 SCAGOA 优化算法改进后的 ML 算法耗时较少,拟合优度更好,稳定性较高。

表 4 基于不同优化算法下估计效果

Tab. 4 Estimation effects based on different optimization algorithms

算法	预估角度的均值	RMSE	成功概率/%
DE-ML	$[20.223\ 2^{\circ}, 40.405\ 4^{\circ}]$	0.856 7	85.9
GWO-ML	$[20.282\ 4^{\circ}, 40.608\ 2^{\circ}]$	0.862 5	85.6
GOA-ML	$[20.309\ 6^{\circ}, 40.904\ 9^{\circ}]$	1.196 4	81.3
SCAGOA-ML	$[20.149\ 1^{\circ}, 40.329\ 9^{\circ}]$	0.853 4	86.7

2.3 与传统经典方法的比较

以上仿真实验都是在不同优化算法下的 DOA 估计对比,接下来比较在不同信噪比(0 dB、5 dB、10 dB)下,本文提出的 SCAGOA-BP 神经网络和 SCAGOA-ML 算法对比传统经典方法 ESPRIT、多重信号分类算法(MUSIC)和 ML 算法的效果。

图 7~图 9 分别是在阵元数为 5,信源数为 2,信噪比为 0 dB、5 dB、10 dB 的仿真条件下,将两

个独立的窄带信号通过入射角度为 $[20^\circ, 40^\circ]$ 的两个阵列后, ESPRIT、MUSIC、ML 3 种传统方法的 DOA 估计效果, 均以谱峰图形式展现, 谱峰值

即为估计角度. 利用 MATLAB 中数据游标将 3 种传统方法的谱峰值坐标显现出来, 将数据记录在表 5 中, 与上文提出的两种方法进行对比.




图 7 0 dB 下传统方法的 DOA 估计效果

Fig. 7 DOA estimation effect of traditional methods under 0 dB




图 8 5 dB 下传统方法的 DOA 估计效果

Fig. 8 DOA estimation effect of traditional methods under 5 dB




图 9 10 dB 下传统方法的 DOA 估计效果

Fig. 9 DOA estimation effect of traditional methods under 10 dB

表 5 记录了 5 种方法的 DOA 估计值、绝对误差以及相对误差, 其中

$$\text{绝对误差} = |\text{预测值} - \text{真实值}|,$$

$$\text{相对误差} = \frac{\text{绝对误差}}{\text{真实值}} \times 100\% =$$

$$\frac{|\text{预测值} - \text{真实值}|}{\text{真实值}} \times 100\%.$$

根据表 5 所得数据得知, 传统 ESPRIT 方法的预测值的误差较小, 但是结合其谱峰图可以看出, 这种方法除预计得到的角度外还存在其他谱峰值. 在进行实测时, 如果对于入射角度的个数以及范围未知时, 可能会对最终结果造成较大干扰. 另外, 本文提出的两种方法的结果和精度都要优于传统的 MUSIC 方法和 ML 方法, 这说明

与传统经典方法相比, SCAGOA-BP 和 SCA - GOA-ML 算法在预测精度方面都有较大优势.

表 5 基于不同信噪比下几种 DOA 估计方法的预测效果

Tab. 5 Prediction effects of several DOA estimation methods based on different SNRS

信噪比/dB	方法	信号 1 估计值 (20°)/(°)	绝对误差/ (°)	相对误差 (×100)	信号 2 估计值 (40°)/(°)	绝对误差 (°)	相对误差 (×100)
0	ESPRIT	21.000 0	1.000 0	5.000 0	39.500 0	0.500 0	1.250 0
	MUSIC	18.000 0	2.000 0	10.000 0	42.000 0	2.000 0	5.000 0
	ML	18.600 0	1.400 0	7.000 0	41.300 0	1.300 0	3.250 0
	SCAGOA-BP	20.300 0	0.300 0	1.500 0	39.600 0	0.400 0	1.000 0
	SCAGOA-ML	20.612 8	0.612 0	3.064 0	39.670 1	0.329 9	0.824 7
5	ESPRIT	20.300 0	0.300 0	1.500 0	39.400 0	0.600 0	1.500 0
	MUSIC	18.500 0	1.500 0	7.500 0	44.000 0	4.000 0	10.000 0
	ML	19.100 0	0.900 0	4.500 0	41.400 0	1.400 0	3.500 0
	SCAGOA-BP	20.300 0	0.300 0	1.500 0	40.260 0	0.260 0	0.650 0
	SCAGOA-ML	20.239 0	0.239 0	0.597 5	40.293 9	0.293 9	0.734 7
10	ESPRIT	19.900 0	0.100 0	0.500 0	39.900 0	0.100 0	0.250 0
	MUSIC	18.000 0	2.000 0	10.000 0	42.000 0	2.000 0	5.000 0
	ML	18.500 0	1.500 0	7.500 0	41.500 0	1.500 0	3.750 0
	SCAGOA-BP	20.100 0	0.100 0	0.500 0	40.250 0	0.250 0	0.625 0
	SCAGOA-ML	20.404 2	0.404 2	2.021 0	40.146 0	0.146 0	0.365 0

3 实 测

通过仿真实验结果可以看出, 利用 SCAGOA 算法优化后的 BP 神经网络和 ML 算法应用于 DOA 估计中, 相比于其他优化算法都取得了较好的估计效果. 在对比 SCAGOA 算法优化的 BP 神经网络和 ML 算法的 RMSE 值后发现, SCAGOA-BP 神经网络的估计精度略高一些, 但在实际测试中, 无法获取实测数据作为 SCAGOA-BP

神经网络的训练样本, 往往会采用仿真实验中的训练样本. 综上, 实测试验中采用 SCAGOA-ML 算法进行测试.

实测实验利用中北大学微米纳米技术研究中心在汾河二库进行的实验数据展开, 将五元矢量水听器固定于船舷一侧, 对固定点声源进行测向, 如图 10 所示, 阵元间距 0.5 m, 置于水下 10 m, 在基阵船 90°方位发射 1 kHz 连续正弦单频信号, 对接收数据用本文方法进行 DOA 估计.




图 10 汾河二库实验图示

Fig. 10 Experimental diagram of Fenhe Erku

主要步骤如下:

- 1) 对试验采集到的数据进行处理, 按照水听器顺序将数据排序分类;
- 2) 计算数据的协方差矩阵, 特征分解得到其

噪声子空间;

- 3) 选择改进的 SCAGOA 优化算法, 将 ML 方法的谱函数作为适应度函数, 在 $[0^\circ, 180^\circ]$ 内对个体进行初始化, 计算初始种群的适应度值;

4) 进入循环, 进行个体种群的位置更新, 求解并记录其适应度值, 与当前最优适应度值进行比较, 更新迭代;

5) 当达到最大迭代次数或误差限制范围时, 结束算法。

图 11 和图 12 分别为 MUSIC 方法和 SCAGOA-ML 方法的实测结果。




图 11 MUSIC 方法实测图

Fig. 11 Actual measurement of MUSIC method




图 12 SCAGOA-ML 方法实测图

Fig. 12 Measured figure of SCAGOA-ML method

MUSIC 方法的预测角度为 89.390° (绝对误差为 0.6100°); SCAGOA-ML 方法的预测角度为 89.5649° (绝对误差为 0.4351°)。在实测环境下, SCAGOA-ML 方法的预估效果要优于传统的 MUSIC 方法, 说明 SCAGOA-ML 方法在实际生活中能够得到很好的应用。

4 结 语

本文主要利用 SCAGOA 算法优化的 BP 神经网络和 ML 算法进行 DOA 估计, 通过 SCAGOA 算法与其他优化算法的对比结果看出, SCAGOA 优化算法一方面解决了传统的 BP 神经网络由于权值和阈值的选取不当易陷入局部最优的问题, 在 SCAGOA-BP 神经网络中估计误差较小, 优势

明显; 另一方面, 在 SCAGOA-ML 方法中, 用改进的智能优化算法改善了传统 ML 方法计算量大、运算速度慢的不足之处, SCAGOA-ML 方法用于 DOA 估计中成功概率更高, 估计精度更准确。在实际应用中, 由于采集数据受噪声等影响较大, 所以去噪将是后期研究的重点。

参考文献:

- [1] 王永良, 陈辉, 彭应宁, 等. 空间谱估计理论与算法 [M]. 北京: 清华大学出版社, 2004.
- [2] Schmidt R, Schmidt R O. Multiple emitter location and signal parameter estimation[J]. IEEE Transactions on Antennas & Propagation, 1986, 34(3): 276-280.
- [3] Santosh S, Sharma K. A review on multiple emitter location and signal parameter estimation[J]. IEEE Transactions on Antennas and Propagation, 2003, 34(3): 276-280.
- [4] 张明星, 王鹏, 白艳萍, 等. 基于 IAFSA-MUSIC 算法的阵列信号 DOA 估计[J]. 数学的实践与认识, 2019, 49(22): 163-170.
Zhang Mingxing, Wang Peng, Bai Yanping, et al. DOA estimation of array signal based on IAFSA-MUSIC algorithm[J]. Mathematics in Practice and Theory, 2019, 49(22): 163-170. (in Chinese)
- [5] Roy R, Paulraj A, Kailath T. ESPRIT—a subspace rotation approach to estimation of parameters of cisoids in noise[J]. IEEE Transactions on Acoustics Speech and Signal Processing, 1986, 34(5): 1340-1342.
- [6] 刘松, 庞育才. 基于扩展 ESPRIT 的随机阵列高效 DOA 估计算法[J]. 电子与信息学报, 2019, 41(6): 1324-1329.
Liu Song, Pang Yucai. Efficient augmented ESPRIT-based direction-of-arrival estimation algorithm for random arrays[J]. Journal of Electronics & Information Technology, 2019, 41(6): 1324-1329. (in Chinese)
- [7] Stoica P, Arye N. MUSIC, maximum likelihood, and Cramer-Rao bound[J]. IEEE Transactions on Acoustics Speech and Signal Processing, 1989, 38(5): 720-741.
- [8] Haykin S, Litva J, Shepherd T J. Exact and large sample maximum likelihood techniques for parameter estimation and detection in array processing[J]. Radar Array Processing, 1993: 99-151.
- [9] Cadzow J A. A high resolution direction-of-arrival al-

- gorithm for narrow-band coherent and incoherent sources [J]. IEEE Transactions on Acoustics, Speech, and Signal Processing, 1988, 36 (7): 965-979.
- [10] 白黄琴, 胡红萍, 白艳萍, 等. 优化的 BP 神经网络在矢量水听器 DOA 估计的研究[J]. 现代电子技术, 2019, 42(23): 31-34.
- Bai Huangqin, Hu Hongping, Bai Yanping, et al. Research on vector hydrophone DOA estimation based on optimized BP neural network[J]. Modern Electronics Technique, 2019, 42 (23): 31-34. (in Chinese)
- [11] 王荣秀, 田雨波, 张贞凯. 基于局部保持投影和 RBF 神经网络的 DOA 估计[J]. 科学技术与工程, 2013, 13(24): 7054-7058.
- Wang Rongxiu, Tian Yubo, Zhang Zhenkai. DOA estimation based on RBFNN and LPP[J]. Science Technology and Engineering, 2013, 13 (24): 7054-7058. (in Chinese)
- [12] 卢金娜. 基于优化算法的径向神经网络模型的改进及应用[D]. 太原: 中北大学, 2015.
- [13] Shahrzad S, Seyedali M, Andrew L. Grasshopper optimisation algorithm: theory and application[J]. Advances in Engineering Software, 2017, 105: 30-47.
- [14] Majdi M, Ibrahim A, Hossam F, et al. Binary grasshopper optimisation algorithm approaches for feature selection problems[J]. Expert Systems With Applications, 2018, 117: 267-286.
- [15] Mirjalili S. SCA: a sine cosine algorithm for solving optimization problems [J]. Knowledge-Based Systems, 2016, 96: 120-133.
- [16] 王远. 正余弦算法及其应用研究[D]. 西安: 西安理工大学, 2019.
- [17] 石磊. 一种改进的正弦余弦优化算法[D]. 武汉: 武汉大学, 2018.

(上接第 170 页)

- [11] 何瑞红. 转台式天线座轴系误差和载荷的分析研究 [D]. 西安: 西安电子科技大学, 2014.
- [12] 李峻岩. 二轴稳瞄转台检测技术研究[D]. 长春: 长春理工大学, 2016.
- [13] 潘健, 习俊通. 基于有限元的三轴测试转台静动态特性研究[J]. 机械设计与制造, 2009(9): 4-6.
- Pan Jian, Xi Juntong. Research on static and dynamic characteristics of a three-axis test turntable based on finite element method[J]. Machinery Design & Manufacture, 2009(9): 4-6. (in Chinese)
- [14] 陈林. 低成本 MEMS 惯性测量组件复合标定与误差补偿方法研究[D]. 沈阳: 沈阳理工大学, 2017.
- [15] 肖桂平. 光学陀螺捷联惯导系统的标定精度分析 [D]. 长沙: 国防科学技术大学, 2008.

(上接第 176 页)

- [10] 李胜利, 石鸿帅, 毋光明, 等. 声发射技术在混凝土空心板桥裂缝检测中的应用[J]. 桥梁建设, 2017, 47(5): 83-88.
- Li Shengli, Shi Hongshuai, Wu Guangming, et al. Application of acoustic emission technology in crack detection of concrete hollow slab bridge[J]. Bridge Construction, 2017, 47(5): 83-88. (in Chinese)
- [11] Chandan K, Bhagat C K, Mukhopadhyay B, et al. Design and development of signal conditioning unit for acquisition of acoustic emission signal for metallic materials[J]. Transactions of the Indian Institute of Metals, 2018, 71(8): 1913-1918.