

DOI: 10.11992/tis.201704007

网络出版地址: <http://kns.cnki.net/kcms/detail/23.1538.TP.20180424.0923.003.html>

基于改进 KH 算法优化 ELM 的目标威胁估计

傅蔚阳¹, 刘以安¹, 薛松²

(1. 江南大学 物联网工程学院, 江苏 无锡 214122; 2. 中国船舶重工集团公司第七研究院 电子部, 北京 100192)

摘要: 为了提高目标威胁度估计的精确度, 建立了反向学习磷虾群算法 (OKH) 优化极限学习机的目标威胁估计模型 (OKH-ELM), 提出基于此模型的算法。该模型使用反向学习策略优化磷虾群算法, 并通过改进后的磷虾群算法优化极限学习机初始输入权重和偏置, 使优化后的极限学习机能够对威胁度测试样本集做更好的预测。实验结果显示, OKH 算法能够更好地优化极限学习机的权值与阈值, 使建立的极限学习机目标威胁估计模型具有更高的预测精度和更强的泛化能力, 能够精准、有效地实现目标威胁估计。

关键词: 目标威胁估计; 磷虾群算法; 极限学习机; 反向学习; 神经网络; 权值; 阈值; 威胁估计模型

中图分类号: TP391.9 **文献标志码:** A **文章编号:** 1673-4785(2018)05-0693-07

中文引用格式: 傅蔚阳, 刘以安, 薛松. 基于改进 KH 算法优化 ELM 的目标威胁估计[J]. 智能系统学报, 2018, 13(5): 693-699.

英文引用格式: FU Weiyang, LIU Yi'an, XUE Song. Target threat assessment using improved Krill Herd optimization and extreme learning machine[J]. CAAI transactions on intelligent systems, 2018, 13(5): 693-699.

Target threat assessment using improved Krill Herd optimization and extreme learning machine

FU Weiyang¹, LIU Yi'an¹, XUE Song²

(1. School of Internet of Things Engineering, Jiangnan University, Wuxi 214122, China; 2. Electronic Department, The Seventh Research Institute of China Shipbuilding Industry Corporation, Beijing 100192, China)

Abstract: To improve the accuracy of target threat estimation, the opposition-based learning Krill Herd optimization (OKH) and extreme learning machine (OKH-ELM) model is established, and the algorithm based on the model is presented. The OKH-ELM adopts opposition-based learning (OBL) to optimize KH, and then the improved KH and extreme learning machine are employed to simultaneously optimize the initial input weights and offsets of the hidden layer in ELM. A target threat database is adopted to test the performance of OKH-ELM in target threat prediction. The experimental result shows that OKH Algorithm can better optimize the weights and thresholds of the hidden layer in ELM and improve the prediction precision and generalization ability of the target threat assessment model; therefore, it can accurately and effectively estimate target threat.

Keywords: target threat assessment; Krill Herd algorithm; extreme learning machine; opposition-based learning; neural networks; weights; thresholds; threat estimation model

严格来讲, 目标威胁估计是一个 NP 困难问题^[1]。在进行威胁估计时, 给出一个各种因素与威胁程度的函数关系困难很大。文献[2]使用 BP 神经网络处理目标威胁估计问题获得了不错

的结果, 但 BP 神经网络也有着明显缺点, 比如训练时间长、易陷入局部极值、学习率 η 选择敏感等。所以本文提出了改进的磷虾群算法 (opposition-based learning Krill Herd optimization, OKH) 优化极限学习机的目标威胁估计模型。磷虾群算法是 2012 年由 Gandomi 等^[3]提出的一种新的仿生优化

收稿日期: 2017-04-12. 网络出版日期: 2018-04-24.

基金项目: 江苏省自然科学基金项目 (BK20160162).

通信作者: 傅蔚阳. E-mail: 18806186287@163.com.

算法。由于其参数少、模型简单、算法性能好而获得大量运用。但是在处理复杂的优化问题时，其易陷入局部极值和出现算法后期收敛速度变慢的问题^[4]。极限学习机^[5-6]是一种针对单隐含层前馈神经网络 (single-hidden layer feedforward neural network, SLFN) 的算法。该算法与传统训练方法相比，具有学习速度快、泛化性能好的优点，但对初始权值与阈值过度依赖^[7]。为解决上述缺点，本文提出了 OKH 算法，利用收集到的目标威胁度数据建立了目标威胁估计模型 (extrem learning machine, ELM)，并使用反向磷虾群算法优化 ELM 模型的初始参数。为了验证本模型的可靠性，将本模型与其他几种神经网络模型作了对比研究。

1 反向磷虾群算法

1.1 标准磷虾群算法

KH 算法是基于自然界磷虾群寻找食物和相互通信的模拟，采用拉格朗日模型模拟磷虾的移动且引入了遗传算子来提高物种多样性^[8-9]。在 KH 算法中，每个磷虾都代表了 n 维解空间中的一个潜在解，磷虾食物代表了算法寻优需要找到的全局最优解。与其他仿生算法相比，磷虾群算法实现起来较为容易，除了时间间隔依据需求人为设定，剩余参数都取自真实生态的研究结果，所以有效避免了因参数设置不当而导致的算法性能下降问题^[10]。该算法具体流程如下。

1) 磷虾个体的速度更新公式为

$$\frac{dX_i}{dt} = N_i + F_i + D_i \quad (1)$$

式中： X_i 为磷虾的状态； N_i 为受诱导运动的速度矢量； F_i 为觅食行为的速度矢量； D_i 为随机扰动的速度矢量；下标 i 表示第 i 只磷虾。

2) 受诱导运动：

$$N_i^{\text{new}} = N^{\text{max}}\alpha_i + \omega_n N_i^{\text{old}} \quad (2)$$

式中： N_i^{new} 为新的受诱导运动速度矢量； $N^{\text{max}} = 0.01 \text{ m/s}$ 为最大诱导速度； $\omega_n \in (0,1)$ 是受诱导运动的惯性权重； N_i^{old} 是上次的受诱导运动速度矢量； α_i 为移动方向， $\alpha_i = \alpha_i^{\text{local}} + \alpha_i^{\text{target}}$ ， α_i^{local} 为相邻磷虾的方向引导， α_i^{target} 是最优磷虾的方向引导。

3) 觅食行为：

$$F_i^{\text{new}} = V_f (\beta_i^{\text{food}} + \beta_i^{\text{best}}) + \omega_f F_i^{\text{old}} \quad (3)$$

式中： F_i^{new} 表示觅食行为产生的速度矢量； V_f 是觅食速度，一般取 0.02 m/s ； $\omega_f \in (0,1)$ 是觅食行为的惯性权重； β_i^{food} 是食物的吸引力； β_i^{best} 是从迭代开始到当前时刻个体 i 的最优状态； F_i^{old} 是上一次觅食行为产生的速度矢量。

4) 随机扰动：

$$D_i = D^{\text{max}} \left(1 - \frac{I}{I_{\text{max}}}\right) \delta \quad (4)$$

式中： $D^{\text{max}} \in [0.002, 0.010] \text{ m/s}$ 是最大扰动速度； δ 为每个变量服从 $(-1, 1)$ 均匀分布的方向矢量。

5) 状态更新：

$$X_i(t + \Delta t) = X_i(t) + \Delta t \frac{dX_i}{dt} \quad (5)$$

式中： Δt 为时间间隔，必须根据实际问题进行选择。

最后，重复进行受诱导运动、觅食行为、随机扰动，直到满足最大迭代次数后寻优停止。

1.2 改进的磷虾群算法

研究可以发现，对于标准磷虾群算法，随着迭代次数的不断增加，所有磷虾个体都朝同方向运动，使得磷虾群趋同性变得严重^[11-12]。本文采用反向学习策略^[13-14]对标准磷虾群算法的初始种群与迭代后的种群进行改进，成功改善了磷虾个体的分布特性和算法的寻优范围，使得算法精度和收敛速度得到较大提高。本算法主要有以下两点改进。

1) 优化初始种群位置

即使没有先验知识的情况下，利用反向点，也能获得一组较好的初始候选解 (初始种群)。过程如下：

① 随机初始化种群 P 。

② 计算反向种群 OP ，即

$$OP_{a,b} = x_a + y_a - P_{a,b} \quad (6)$$

式中： $a = 1, 2, \dots, N_p$ ； $b = 1, 2, \dots, n$ ； $OP_{a,b}$ 和 $P_{a,b}$ 分别表示反向种群位置与种群位置中 a 维第 b 个变量的值； x_a 和 y_a 分别表示第 a 维元素的最大值和最小值。

③ 分别计算 P 与 OP 中个体的适应度，从中取适应度值较好的 n 个体生成新的初始种群 NP 。

2) 优化迭代过程中的种群位置

同理，如果在迭代的过程中也使用类似的反向学习方法，就能够提高算法的全局搜索能力。算法迭代开始前，设置反向学习优化选择概率 p 。每当完成一次迭代，计算出新的种群位置后，依据 p 来决定是否对种群进行反向学习优化 (p 的大小根据实际需要决定)。过程如下：

① 生成一个随机数 $\text{rand}(0,1)$ 。如果 $\text{rand}(0,1) < p$ ，则转入②，否则，直接进入算法下一轮迭代。

② 计算动态反向种群 OP ：

$$OP_{a,b} = \text{Min}'_a + \text{Max}'_a - P_{a,b} \quad (7)$$

式中， Min'_a 与 Max'_a 分别表示第 t 次迭代第 a 维元素的最小值与最大值。

③ 使用适应度评价函数计算 P 和与其对应的 OP 中个体的适应度值。如果 $f'_i < f_i$ ，则用 OP_i

替代 P_i , 全部比较、替换后的种群 P 就是新的种群。其中, f_i, f'_i 分别表示第 i 个个体和与其对应的反向个体的适应度值, OP_i 表示第 i 个反向个体。

④进入下一轮 OKH 迭代。

随着搜索进程的深入, 当前迭代的搜索区间远小于最初的搜索区间, 使得种群快速逼近最优解。

OKH 算法流程: ①参数初始化, 即最大迭代次数 I 、种群规模 N 、最大扰动速度 D^{\max} 、时间间隔 Δt 以及优化选择概率 p ; ②初始化种群位置并利用反向学习优化初始种群位置; ③计算此时每个磷虾个体对应的适应度值; ④分别计算受诱导运动、觅食行为、随机扰动所产生的个体位置变化量; ⑤使用公式 (5) 更新磷虾位置; ⑥生成 $\text{rand}(0,1)$, 如果 $\text{rand}(0,1) < p$, 根据公式 (7) 计算动态反向种群并计算 P 与 OP 中个体的适应度值。如果 $f'_i < f_i$, 则用 OP_i 替代 P_i , 生成新的种群, 否则直接进入 ⑦; ⑦计算磷虾个体新位置矢量的适应度, 然后重复 ④ ~ ⑦, 直到达到最大迭代次数, 算法结束; ⑧输出最终的迭代结果, 即最优解。

1.3 算法性能分析

为了验证 OKH 算法, 选择 6 个基准测试函数

进行仿真分析与标准 KH 算法、PSO 算法作比较。测试函数见表 1。

表 1 测试函数
Table 1 Test functions

编号	函数名	搜索空间	最优值
f_1	Step	(-100,100)	0
f_2	Schwefel 2.22	(-10,10)	0
f_3	Sphere	(-100,100)	0
f_4	Griewank	(-600,600)	0
f_5	Ackley	(-100,100)	0
f_6	Rastrigin	(-5.12,5.12)	0

OKH 算法和 KH 算法的参数设置一致: 最大扰动速度 $D^{\max}=0.005$ m/s, 觅食速度 $V_f=0.02$ m/s, 最大诱导速度 $N^{\max}=0.01$ m/s。特别的, OKH 中反向学习优化选择概率 $p=0.5$ 。PSO 参数设置为学习因子 $c_1=c_2=1.5$ 。为保证公平性, 3 种算法的其他参数一致: 初始种群规模为 30, 最大迭代次数为 200, 维数为 10, 运行次数为 10。将 10 次寻优的最优值、最差值、平均值以及均方差记录下来。实验结果如表 2 所示。

表 2 3 种算法的性能比较
Table 2 Comparison of three algorithms

函数	算法	最优值	最差值	平均值	标准差
f_1	PSO	2.977×10^{-3}	6.997	1.377	2.207
	KH	8.290×10^{-5}	1.868×10^{-3}	6.115×10^{-4}	6.543×10^{-4}
	OKH	5.529×10^{-5}	1.956×10^{-4}	1.091×10^{-4}	5.055×10^{-5}
f_2	PSO	2.328×10^{-1}	3.490	1.457	1.244
	KH	3.105×10^{-4}	1.372	2.730×10^{-1}	4.589×10^{-1}
	OKH	2.477×10^{-8}	1.025×10^{-5}	2.136×10^{-6}	3.113×10^{-6}
f_3	PSO	2.551×10^{-5}	3.625	5.892×10^{-1}	1.245
	KH	5.494×10^{-5}	1.937×10^{-2}	5.658×10^{-4}	6.532×10^{-4}
	OKH	4.845×10^{-5}	9.231×10^{-4}	4.048×10^{-4}	2.911×10^{-4}
f_4	PSO	1.559×10^{-1}	1.449	5.656×10^{-1}	4.020×10^{-1}
	KH	5.119×10^{-2}	1.515×10^{-1}	9.381×10^{-2}	3.495×10^{-2}
	OKH	9.224×10^{-3}	1.027×10^{-1}	3.019×10^{-2}	2.681×10^{-2}
f_5	PSO	1.146×10^{-2}	3.575	2.040	9.773×10^{-1}
	KH	4.457×10^{-2}	9.156×10^{-2}	6.205×10^{-2}	1.649×10^{-2}
	OKH	2.635×10^{-8}	1.739×10^{-4}	3.214×10^{-5}	5.455×10^{-5}
f_6	PSO	5.112	21.920	14.890	5.242
	KH	9.952×10^{-1}	8.962	4.581	2.355
	OKH	3.301×10^{-4}	2.479×10^{-3}	8.952×10^{-4}	7.160×10^{-4}

由表 2 可以发现,相较于 KH 算法、PSO 算法,OKH 算法具有更好的寻优效果。尤其在多峰函数中表现更为优异,不仅搜索精度更高而且跳出局部最优的能力更强。从均方差可知,OKH 算法的鲁棒性也优于另外两种算法。

2 基于 OKH-ELM 的目标威胁估计

2.1 目标威胁估计因素

目标威胁估计问题需要统筹的因素很多,比如天气、地形、敌、我、邻军的战斗力及兵力部署和指战员作战风格等^[15-16]。进行威胁估计时,通常需考虑以下的因素:

- 1) 目标类型:大型目标(强击机、轰炸机等)、小型目标(隐身飞机、空地导弹等)、武装直升机。
- 2) 目标速度:如 30 m/s、44 m/s、120 m/s 等。
- 3) 目标方位角:如 3°、6°、9°等。
- 4) 目标高度:如低空、中空、高空。
- 5) 目标抗干扰能力:如无、弱、中、强。
- 6) 目标距离:如 50 km、100 km、150 km 等。

2.2 OKH-ELM 目标威胁估计模型

对于随机产生初始输入权值和阈值的极限学习机,很难保证训练的 ELM 模型拥有较好的泛化能力和较高的预测精度^[17-18]。针对以上不足,本文在采用极限学习机建立目标威胁估计模型的基础上,利用 OKH 算法优化 ELM 初始输入权重和偏置,提出了基于 OKH-ELM 的目标威胁估计模型。模型优化过程如图 1 所示。

1) 数据预处理

收集 105 组数据,大型目标、小型目标和武装直升机各 35 组。随机选择大型目标、小型目标和武装直升机各 30 组,共 90 组,做训练集,剩余 15 组做测试集。部分数据如表 3 所示。

使用 9 级量化理论对威胁属性量化^[19]。对定性属性做如下预处理。

①目标高度:超低、低、中、高,依次量化为 2、4、6、8。

②目标抗干扰能力:强、中、弱、无,依次量化为 2、4、6、8。

③目标类型:大型目标、小型目标、武装直升机依次量化为 3、5、8。

对于目标距离、目标方向角和目标速度则直接进行归一化操作。

2) 确定 ELM 网络拓扑结构

ELM 隐含层神经元个数与训练集样本个数有关,经多次实验,设置 20 个神经元预测结果较

好。ELM 三层网络拓扑结构为 6-20-1,输入层与隐含层间连接权值及隐含层神经元阈值的寻优范围均为[-1,1],隐含层激活函数为 Sigmoid。

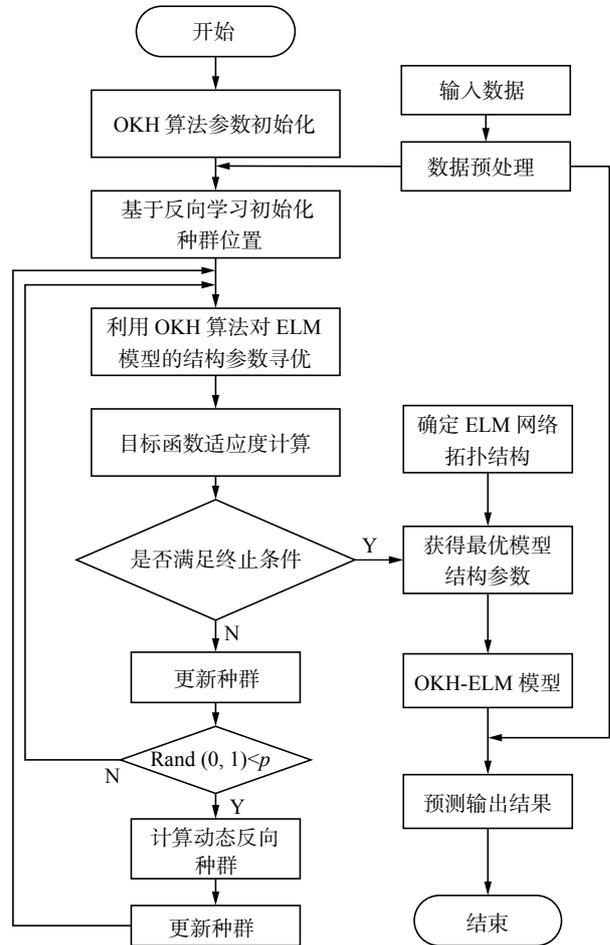


图 1 基于 OKH-ELM 的目标威胁估计模型
Fig. 1 Model of target threat assessment using OKH-ELM

表 3 部分数据

Table 3 Parts of data

序号	类型	$v/m \cdot s^{-1}$	$\theta/(^\circ)$	h	a	d/km	T
1	大	600	8	低	中	110	0.668 2
2	大	540	12	高	强	290	0.531 2
3	大	480	7	中	中	260	0.572 8
4	小	750	14	低	中	360	0.744 7
5	小	920	17	高	强	390	0.732 2
6	小	970	3	中	中	220	0.843 7
7	直升机	110	17	中	无	150	0.312 0
8	直升机	104	5	高	弱	160	0.372 7
9	直升机	103	9	中	无	230	0.358 6

注: v 为目标速度; θ 为目标方位角; h 为目标高度; a 为目标抗干扰能力; d 为目标距离; T 为目标威胁值。

3)OKH 参数初始化

OKH 算法的参数设置与 1.3 节的 OKH 参数设置相同。

4)OKH 初始化种群

个体编码方法采用实数编码, 用实数串表示每个个体。该实数串由 ELM 输入层与隐含层之间的权值和隐含层的阈值两部分组成。因为 ELM 网络结构为 6-20-1, 所以磷虾个体的编码长度为 $6 \times 20 + 20 = 140$ 。

5) 目标适应度函数

$$f = k \left(\sum_{i=1}^n |y_i - o_i| \right) \quad (8)$$

式中: n 为测试样本数, y_i 为模型的训练输出威胁度, o_i 为实际威胁度, k 为常数。

6) 执行 OKH 算法

OKH 算法流程与 1.2 节的 OKH 算法流程相同。

7) 预测输出

利用 OKH 算法优化好的初始权值与阈值来构造 ELM。将测试集数据输入已经训练过的 ELM, 预测目标威胁度。

3 模型性能分析

为测试 OKH-ELM 目标威胁估计模型的有效性, 将测试数据分别输入 OKH-ELM、ELM、KH-ELM、KH-BP、PSO-ELM 模型比较预测输出。

KH-ELM 模型、PSO-ELM 模型的建立与 OKH-ELM 相似, 仅将优化函数分别改成标准 KH 算法和 PSO 算法。KH-BP 模型利用 KH 算法优化 BP 神经网络初始的全部权值和阈值^[20], 采用 6-11-1 的网络结构, 磷虾个体编码长度为 $6 \times 11 + 11 + 1 = 89$ 。采用训练好的上述 5 种模型分别对相同的威胁度测试集进行预测, 实验结果如图 2、图 3 和表 4 所示。

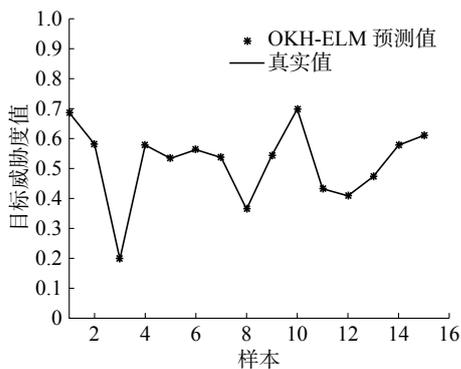


图 2 OKH-ELM 的预测威胁值与真实威胁值对比

Fig. 2 Comparison between forecasting values and real threat values based on OKH-ELM

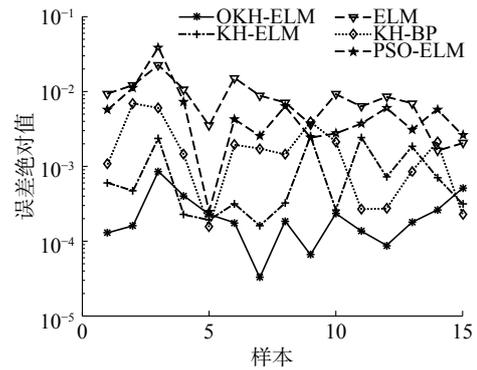


图 3 5 种模型的预测误差绝对值

Fig. 3 Absolute predictive error for five models

表 4 5 种优化方法的绝对预测误差平均值

Table 4 Average of absolute predictive errors of five optimization methods

方法	预测误差
ELM	8.522×10^{-3}
PSO-ELM	6.850×10^{-3}
KH-BP	2.028×10^{-3}
KH-ELM	9.011×10^{-4}
OKH-ELM	2.436×10^{-4}

由图 2 可知, OKH-ELM 模型输出的预测威胁值与真实威胁值拟合度很高。由图 3、表 4 可知, OKH-ELM 威胁估计模型的预测误差平均值小于其他 4 种威胁估计模型, 预测结果最接近真实值。除了在第 4、5、15 个样本处, OKH-ELM 模型预测误差不是最小 (但也十分接近最小误差), 其余样本点预测误差均最小。5 种模型的优异度排序为: OKH-ELM > KH-ELM > KH-BP > PSO-ELM > ELM。实验结果显示, 本文构造的 OKH-ELM 目标威胁估计模型能够较好地应对目标威胁估计问题, 模型性能优于另外 4 种模型。

4 结束语

本文针对多源信息融合中目标威胁估计的特点, 利用改进磷虾群算法与极限学习机, 建立了一种基于改进磷虾群算法优化极限学习机的目标威胁估计模型, 并提出了该模型的算法。文中选取影响目标威胁估计的 6 个典型指标, 采集了 105 组数据用于仿真实验。结果表明, 相比于 ELM、PSO-ELM、KH-BP、KH-ELM, OKH-ELM 模型能够更加准确、有效地预测目标威胁值, 为目标威胁估计提供了一种新的方法。

参考文献:

[1] 姚磊, 王红明, 郑锋, 等. 空中目标威胁估计的模糊聚类方法研究[J]. 武汉理工大学学报: 交通科学与工程版,

- 2010, 34(6): 1159–1161, 1166.
- YAO Lei, WANG Hongming, ZHENG Feng, et al. Study fuzzy clustering method of air target threat assessment[J]. Journal of Wuhan university of technology: transportation science & engineering, 2010, 34(6): 1159–1161, 1166.
- [2] 王改革, 郭立红, 段红, 等. 基于萤火虫算法优化 BP 神经网络的目标威胁估计[J]. 吉林大学学报: 工学版, 2013, 43(4): 1064–1069.
- WANG Gaige, GUO Lihong, DUAN Hong, et al. Target threat assessment using glowworm swarm optimization and BP neural network[J]. Journal of Jilin university: engineering and technology edition, 2013, 43(4): 1064–1069.
- [3] GANDOMI A H, ALAVI A H. Krill herd: a new bio-inspired optimization algorithm[J]. Communications in nonlinear science and numerical simulation, 2012, 17(12): 4831–4845.
- [4] 黄璇, 郭立红, 李姜, 等. 磷虾群算法优化支持向量机的威胁估计[J]. 光学精密工程, 2016, 24(6): 1448–1455.
- HUANG Xuan, GUO Lihong, LI Jiang, et al. Threat assessment of support vector machine optimized by Krill Herd algorithm[J]. Optics and precision engineering, 2016, 24(6): 1448–1455.
- [5] HUANG Guangbin, CHEN Lei. Enhanced random search based incremental extreme learning machine[J]. Neurocomputing, 2008, 71(16/18): 3460–3468.
- [6] 林梅金, 罗飞, 苏彩虹, 等. 一种新的混合智能极限学习机[J]. 控制与决策, 2015, 30(6): 1078–1084.
- LIN Meijin, LUO Fei, SU Caihong, et al. An improved hybrid intelligent extreme learning machine[J]. Control and decision, 2015, 30(6): 1078–1084.
- [7] HUANG Guangbin, ZHU Qinyu, SIEW C K. Extreme learning machine: a new learning scheme of feedforward neural networks[C]//Proceedings of 2004 IEEE International Joint Conference on Neural Networks. Budapest, Hungary, 2004: 985–990.
- [8] 杜长海. 基于磷虾群算法的 SVR 参数选取方法及其应用[J]. 自动化技术与应用, 2016, 35(5): 10–14, 19.
- DU Changhai. Parameters selection method for support vector regression based on Krill Herd algorithm and its application[J]. Techniques of automation and applications, 2016, 35(5): 10–14, 19.
- [9] WANG Gaige, GANDOMI A H, ALAVI A H. Stud krill herd algorithm[J]. Neurocomputing, 2014, 128: 363–370.
- [10] MUKHERJEE A, MUKHERJEE V. Solution of optimal power flow using chaotic krill herd algorithm[J]. Chaos, solitons and fractals, 2015, 78: 10–21.
- [11] BOLAJI A L, AL-BETAR M A, AWADALLAH M A, et al. A comprehensive review: Krill Herd algorithm (KH) and its applications[J]. Applied soft computing, 2016, 49: 437–446.
- [12] LI Junpeng, TANG Yinggan, HUA Changchun, et al. An improved krill herd algorithm: Krill herd with linear decreasing step[J]. Applied mathematics and computation, 2014, 234: 356–367.
- [13] 康岚兰, 董文永, 田降森. 一种自适应柯西变异的反向学习粒子群优化算法[J]. 计算机科学, 2015, 42(10): 226–231.
- KANG Lanlan, DONG Wenyong, TIAN Jiangsen. Opposition-based particle swarm optimization with adaptive Cauchy mutation[J]. Computer science, 2015, 42(10): 226–231.
- [14] TIZHOOSH H R. Opposition-Based reinforcement learning[J]. Journal of advanced computational intelligence and intelligent informatics, 2006, 10(4): 578–585.
- [15] 武传玉, 刘付显. 基于模糊评判的新防空威胁评估模型[J]. 系统工程与电子技术, 2004, 26(8): 1069–1071.
- WU Chuanyu, LIU Fuxian. New model of target threat assessment for air defense operation based on fuzzy theory[J]. Systems engineering and electronics, 2004, 26(8): 1069–1071.
- [16] 刘海波, 王和平, 沈立顶. 基于 SAPSO 优化灰色神经网络的空中目标威胁估计[J]. 西北工业大学学报, 2016, 34(1): 25–32.
- LIU Haibo, WANG Heping, SHEN Liding. Target threat assessment using SAPSO and grey neural network[J]. Journal of northwestern polytechnical university, 2016, 34(1): 25–32.
- [17] HUANG Guangbin, ZHOU Hongming, DING Xiaojian, et al. Extreme learning machine for regression and multi-class classification[J]. IEEE transactions on systems, man, and cybernetics-Part B: cybernetics: a publication of the IEEE systems, man and cybernetics society, 2012, 42(2): 513–529.
- [18] HUANG Guangbin, DING Xiaojian, ZHOU Hongming. Optimization method based extreme learning machine for classification[J]. Neurocomputing, 2010, 74(1/2/3): 155–163.
- [19] YAO Yueting, ZHAO Jianjun, WANG Yi, et al. MADM of threat assessment with attempt of target[M]// KIM H. Advances in Technology and Management. Berlin, Heidelberg: Springer, 2012: 171–179.
- [20] KOWALSKI P A, ŁUKASIK S. Training neural networks with Krill Herd algorithm[J]. Neural processing letters, 2016, 44(1): 5–17.

作者简介:



傅蔚阳, 男, 1993 年生, 硕士研究生, 主要研究方向为雷达对抗、人工智能。



刘以安, 男, 1963 年生, 教授, 博士, 主要研究方向为数据融合与数据挖掘、雷达对抗、模式识别与智能系统。主持或参与教育部、国防科工委、江苏省教育厅等省部级项目 5 项。发表学术论文 60 余篇。



薛松, 男, 1987 年生, 工程师, 主要研究方向为信号与信息处理、内场仿真系统设计。发表学术论文 2 篇。

2018 年机器人与人工智能国际会议 (JCRAI 2018) 2018 International Joint Conference on Robotics and Artificial Intelligence (JCRAI 2018)

2018 International Joint Conference on Robotics and Artificial Intelligence(JCRAI 2018) will be held in Wellington, New Zealand on Dec 10–12,2018.

JCRAI 2018 welcomes researchers, engineers, scientists and industry professionals to an open forum where advances in the field of Robotics and Artificial Intelligence can be shared and examined. The conference is an ideal platform for keeping up with advances and changes to a consistently morphing field. Leading researchers and industry experts from around the globe will be presenting the latest studies through papers and oral presentations.

Submission

Please submit your papaer to: jcrai@iased.org OR submit via Online Submission System

All submitted papers need to be original, must not be previously published or accepted for publication elsewhere. Must not be under review by any other conference or publication during the review cycle.

Please find the paper format here(submitted papers need to follow the required fonts strictly):

Paper Submission(Authors):Paper Format

Abstract Submission (Presenters): Abstract Format

All submitted papers will go through a double-blind reviewing process by at least two reviewers drawn from the chairs of committees, also if you dont want to publish any paper, you are welcome to join us as presenter, listener, etc.

Publication

All accepted papers will be published in the digital conference proceedings which will be Indexed by all major citation databases such as Ei Compendex, SCOPUS, Google Scholar, Cambridge Scientific Abstracts (CSA), Inspec, SCImago Journal & Country Rank (SJR), EBSCO, CrossRef, Thomson Reuters (WoS), etc.

Selected Papers from JCRAI 2018 will be published in journals.