

DOI: 10.11830/ISSN.1000-5013.201703113



采用人群搜索算法的径向基函数神经网络参数整定方法

何莉, 肖茗方, 张威亚

(湖北工业大学 电气与电子工程学院, 湖北 武汉 430068)

摘要: 针对径向基函数(RBF)神经网络的逼近结构中,对权值、基宽和中心向量的初始值等参数的选取不当,导致系统的鲁棒性变差、收敛精度降低,甚至不再收敛的问题,提出一种基于人群搜索算法的 RBF 神经网络的参数整定方法.以基于遗传算法和基于粒子群算法的 RBF 神经网络参数整定方法为对比条件,采用 MATLAB 软件进行实验与分析.结果表明:应用人群搜索算法去优化 RBF 神经网络的初始参数,能有效地提升 RBF 神经网络的逼近精度,验证了该算法的可行性.

关键词: 径向基函数神经网络; 人群搜索算法; 逼近精度; 可行性

中图分类号: TP 183 **文献标志码:** A **文章编号:** 1000-5013(2018)02-0299-07

Parameter Adjusting Method of Radial Basis Function Neural Network Using Seeker Optimization Algorithm

HE Li, XIAO Mingfang, ZHANG Weiya

(School of Electrical and Electronic Engineering, Hubei University of Technology, Wuhan 430068, China)

Abstract: In the approximation structure of radial basis function (RBF) neural network, its improper parameters such as weight, base width and initial value of the center vector will leads to poor system robustness and reduced convergence accuracy, or even no convergence. Aiming at this problem, the parameter adjusting method of RBF neural network based on seeker optimization algorithm is proposed. And using the parameter adjusting method of RBF neural network based on genetic algorithm and particle swarm optimization as comparison, the experiment and analysis are completed by MATLAB software. The results show that the seeker optimization algorithm can optimize the initial parameters of RBF neural network, so that the approximation accuracy of RBF neural network is effectively improved, and the feasibility of the algorithm is verified.

Keywords: radial basis function neural network; seeker optimization algorithm; approximation accuracy; feasibility

由于神经网络在非线性系统建模和非线性优化逼近方面的优势,已经被广泛应用于解决控制系统的非线性问题中^[1]. 径向基函数(radial basis function, RBF)是在 20 世纪 80 年代末提出的一种局部逼近的神经网络结构^[2-3], 相比反向传播(BP)神经网络结构^[4], RBF 神经网络在系统要求具有高度实时性控制能力方面比较优越,能迅速、有效地避免陷入局部最小和以任意精度逼近任意连续函数的优势,逐渐成为智能控制领域研究的热点^[5-7]. 采用 RBF 神经网络控制方案的控制系统,能够以任意精度逼近任

收稿日期: 2017-03-06

通信作者: 何莉(1980-),女,副教授,博士,主要从事电力系统优化调度、系统分析与集成的研究. E-mail: heli_edu@hotmail.com.

基金项目: 国家自然科学基金资助项目(51379081); 国家留学基金资助项目(201608420056); 湖北省重大科技创新计划项目(2013AEA001)

意连续函数,以其精度高、鲁棒性和自适应性强等优点,可更好地处理具有连续函数的控制系统^[8-9].但是,如果 RBF 神经网络的权值(ω)、高斯基函数的中心矢量(c)和基宽向量(b)等参数的初始值选取不当,也可能导致逼近精度的下降,甚至 RBF 神经网络的发散,无法完成 RBF 神经网络的优化逼近^[10].因此,RBF 神经网络参数的初始值恰当选取,对满足系统要求的逼近精度尤其重要.寻找一种对 RBF 神经网络参数初始值进行整定的算法且能保证可靠、高精度的逼近系统,这一直是智能控制领域中学者们研究的方向和目标^[11].本文将人群搜索算法(seeker optimization algorithm,SOA)^[12-13]应用于 RBF 神经网络初始参数的整定,通过 MATLAB 进行算法实现和分析,并验证该算法的可行性.

1 RBF 神经网络的逼近

图 1 为 RBF 神经网络结构原理.以多输入、单输出的结构为例进行分析, $\mathbf{X}=[x_1,x_2,x_3,x_4,\cdots,x_m]^T$,表示 RBF 神经网络结构中的输入向量.对应的 RBF 神经网络逼近原理,如图 2 所示.

设 RBF 网络的径向基向量 $\mathbf{H}=[h_1,h_2,h_3,h_4,\cdots,h_m]^T$,高斯基函数 $h_j=\exp(-\frac{\|\mathbf{X}-\mathbf{C}_j\|^2}{2b_j^2})$, $j=1,2,\cdots,n$.其中: $\mathbf{C}=[c_{j,1},c_{j,2},c_{j,3},\cdots,c_{j,m}]^T$, $j=1,2,\cdots,n$,表示网络中第 j 个节点的中心向量,有

$$\mathbf{C}=\begin{bmatrix} c_{1,1} & c_{2,1} & \cdots & c_{j,1} & \cdots & c_{n,1} \\ c_{1,2} & c_{2,2} & \cdots & c_{j,2} & \cdots & c_{n,2} \\ \vdots & \vdots & & \vdots & & \vdots \\ c_{1,m} & c_{2,m} & \cdots & c_{j,m} & \cdots & c_{n,m} \end{bmatrix}.$$

设基宽向量为 $\mathbf{B}=[b_1,b_2,b_3,\cdots,b_n]^T$,其中, $b_j>0$,表示节点 j 的基宽参数值. $\mathbf{W}=[w_1,w_2,w_3,\cdots,w_n]^T$ 作为网络权向量,则对应的网络输出为

$$y_m(k)=\mathbf{W}^T\mathbf{H}=w_1h_1+w_2h_2+\cdots+w_nh_n. \tag{1}$$

采用梯度下降法,可得相关参数的迭代方程为

$$w_j(k)=w_j(k-1)+\eta(y(k)-y_m(k))h_j+\alpha(w_j(k-1)-w_j(k-2)), \tag{2}$$

$$b_j(k)=b_j(k-1)+\eta(y(k)-y_m(k))w_jh_j\frac{\|\mathbf{X}-\mathbf{C}_j\|^2}{b_j^2}+\alpha(b_j(k-1)-b_j(k-2)), \tag{3}$$

$$c_{j,i}(k)=c_{j,i}(k-1)+\eta(y(k)-y_m(k))w_jh_j\frac{X-C_{j,i}}{b_j^2}+\alpha(c_{j,i}(k-1)-c_{j,i}(k-2)). \tag{4}$$

式(2)~(4)中: η 为学习速率, $\eta\in[0,1]$; α 为动量因子, $\alpha\in[0,1]$.

2 人群搜索算法

人群搜索算法(SOA)是一种较新的基于种群的启发式搜索智能算法^[12-13].该算法主要模拟的是人类活动,通过搜索队伍作为种群的方式,模仿人类一系列的利他行为、利己行为、预动行为和不确定推理等行为,实现方向和步长搜寻,进一步实现位置更新,最后完成寻优的功能^[14-15].

图 3 为人群搜索算法的流程,主要有以下 7 个步骤.

步骤 1 $t=1$,第一代群体,即初始迭代次数,此后,每迭代一次 $t+1$.

步骤 2 初始化,在可行解域内,随机产生 S 个初始位置.

步骤 3 评价个体的初始位置,即对每个位置对应的目标函数值进行进一步计算.

步骤 4 计算每一个个体 i 在每一维 j 的搜索方向 $d_{i,j}(t)$ 和步长 $\alpha_{i,j}(t)$,为位置更新提供搜寻策略.




图 1 RBF 神经网络结构原理 Fig. 1 Principle of RBF neural network structure

图 2 RBF 神经网络逼近原理 Fig. 2 Principle of RBF neural network approach

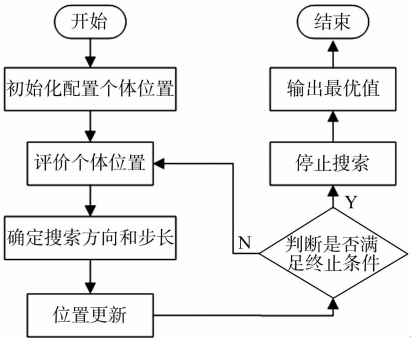


图 3 人群搜索算法流程图 Fig. 3 Seeker optimization algorithm flow chart

- 步骤 5** 个体位置进行更新操作,即根据搜索策略确定的搜索方向和步长,按一定公式更新搜寻者的位置.
- 步骤 6** $t \rightarrow t+1$,迭代次数加 1.
- 步骤 7** 判断是否满足停止条件,如满足,则停止搜索并输出最优值;否则,跳回执行步骤 3.

3 基于人群搜索算法的 RBF 逼近

3.1 参数选取与设计

选取 RBF 神经网络的结构,设置为 2 个输入层、3 个隐层和 1 个输出层. 为避免选取参数范围过大,先以经验的方式选取一组初始参数,并在此基础上,利用算法实现对周围参数的寻优. 这样可大大地避免初始值寻优的盲目性,节约不必要的计算量.

设网络惯性权值 $\omega_i \in [-1, 1]$,高斯函数基宽向量元素 $b_j \in [0.1, 30.0]$,中心矢量元素 $c_{i,j} \in [-3, 3]$,对应的 $i=1, 2; j=1, 2, 3$. 所以,需要进行优化的参数共有 12 个,即 $P=[b_1, b_2, b_3; c_{1,1}, c_{1,2}, c_{1,3}, c_{2,1}, c_{2,2}, c_{2,3}; \omega_1, \omega_2, \omega_3]$. 为了实现提高 RBF 网络逼近精度的目的,将最小目标函数设置为误差绝对值,即

$$J = 100 \sum_{k=1}^N |y(k) - y_m(k)|.$$

(5)

式(5)中: N 为逼近的总步骤,通过 RBF 逼近 N 次后,比较不同的误差大小作为评价个体位置更新的指标; $y(k)$ 和 $y_m(k)$ 分别为没有应用 RBF 和应用 RBF 神经网络的输出函数.

以使用 SOA 算法优化的 RBF 网络逼近下列函数为例,有

$$y(k) = u^3(k) + y(k-1)/[1 + y^2(k-1)].$$

(6)

式(6)中:输入信号为 2 个,即 $u(k)$ 和 $y(k-1)$. 文中以输入信号 $u(k) = \sin(10\pi t) - e^t + t + 1$ 为例.

应用 SOA 算法对 RBF 神经网络初始参数整定的具体步骤可描述为:将式(6)作为最小目标函数,取 $N=500$,随机选取上述设定参数范围中的 12 个数,通过应用 SOA 算法,对每一代中个体代表的数值进行 RBF 神经网络的逼近;寻得逼近误差最小的个体,以该个体为全局最佳进行下一代种群个体位置更新. 算法的最终结果是得到全部个体中使 RBF 神经网络逼近误差最小的个体. 即得到 RBF 神经网络的初始参数,并将所得参数代入 RBF 神经网络逼近中.

3.2 仿真结果及分析

为更好地验证 SOA 算法对 RBF 神经网络参数整定的性能,与文献[16-17]中遗传算法(GA)优化 RBF 和文献[18]中粒子群优化算法(PSO)优化 RBF 进行对比.

1) 针对 GA 算法. 首先,根据其不同的交叉概率(p_c)和变异概率(p_m)的组合,对 RBF 神经网络参数进行大量寻优实验,寻找使优化结果达到最优值时所对应的交叉概率和变异概率值;然后,在此基础上,以确定交叉概率值和变异概率值的 GA 算法为对比对象,通过设置不同的条件,实现与 SOA 算法寻优的对比.

设置 GA 算法种群规模为 $S=30$ 和最大迭代次数为 $N=200$,得出 GA 算法不同交叉概率和变异概率组合下寻得的对比结果,如表 1 所示. 表 1 中:对每种参数组合下的 GA 算法进行独立 200 次的 RBF 神经网络参数寻优实验,取 200 次结果的平均目标函数值 J_{avg} 和 200 次结果中的最小目标函数值 J_{min} 为 GA 算法最优参数选取依据.

表 1 GA 算法最优组合参数选取
Tab. 1 Optimal combination parameter selection of GA algorithm

p_m	p_c	J_{avg}	J_{min}	p_m	p_c	J_{avg}	J_{min}
1.0	1.0	225.010 5	189.365 8	0.7	1.0	238.602 3	206.863 0
	0.8	206.745 1	184.323 9		0.8	219.836 5	179.989 8
	0.6	223.400 5	194.293 3		0.6	228.164 8	198.717 3
	0.4	233.702 1	186.237 7		0.4	224.663 1	181.050 2
	0.2	211.630 0	181.809 4		0.2	237.012 6	210.330 0
	0	209.748 8	194.907 4		0	222.250 9	195.598 5

续表

Continue table

p_m	p_c	J_{avg}	J_{min}	p_m	p_c	J_{avg}	J_{min}
0.9	1.0	237.400 1	187.690 3	0.6	1.0	250.494 8	226.779 6
	0.8	252.666 7	179.160 6		0.8	226.225 3	170.264 3
	0.6	222.332 1	177.143 9		0.6	209.414 6	199.447 7
	0.4	208.600 2	169.837 6		0.4	217.502 8	214.136 4
	0.2	202.185 4	167.135 7		0.2	235.001 1	172.052 2
	0	211.203 4	197.301 9		0	237.757 3	230.727 5
0.8	1.0	207.163 1	179.042 4	0.5	1.0	223.479 3	195.145 9
	0.8	225.600 1	214.098 6		0.8	223.811 7	200.978 9
	0.6	206.833 3	191.803 7		0.6	282.666 0	259.790 0
	0.4	197.217 6	175.810 4		0.4	230.330 4	212.091 2
	0.2	198.854 3	183.208 5		0.2	203.094 9	185.575 0
	0	204.103 9	191.328 6		0	295.350 1	265.935 4
				⋮	⋮	⋮	⋮

由表 1 可知:变异概率(p_m)的步长设置为 0.1,交叉概率(p_c)的步长设置为 0.2,两者搭配组合后,进行 GA 算法的 RBF 神经网络参数优化实验,得到所有结果中的最小目标函数值 $J_{min}=167.135\ 7$. 此时,交叉概率 $p_c=0.2$,变异概率 $p_m=0.9$,而平均目标函数值 $J_{avg}=202.185\ 4$,也比较小,可选择此时的交叉概率和变异概率为 GA 算法的最优参数.

2) 针对 PSO 算法. 由于 PSO 算法容易早熟及后期易在全局最优解附近产生振荡,可以采用权重因子线性递减的 PSO 算法,让惯性权重从最大值 ω_{max} 线性减小到最小值 ω_{min} ,随着算法迭代次数的变换,其计算式为

$$\omega = \omega_{max} - t \cdot (\omega_{max} - \omega_{min}) / t_{max}.$$

其中: t 为当前迭代次数; t_{max} 为最大迭代次数;通常取 $\omega_{max}=0.9$, $\omega_{min}=0.4$. 和文献[18]取值相同,经过大量的 PSO 算法优化 RBF 网络的实验,选择学习因子 $c_1=c_2=1.494\ 45$ 可实现很好的效果.

3) 针对 SOA 算法. 由于 SOA 算法的高斯隶属函数表示搜索步长模糊变量,即

$$u_A(x) = \exp(-(x-u)^2/2\sigma^2).$$

式中: $u_A(x)$ 为高斯隶属度; x 为输入变量; u,σ 为隶属函数参数,当输出变量超出 $[u-3\sigma,u+3\sigma]$ 时,如果其隶属度 $(u_A(u+3\sigma)<2\sigma^2)$ 可以忽略,故设定最小隶属度 $u_{min}=0.011\ 1$.

在不确定推理的过程中,为了设计一个适用于大多数优化问题的模糊系统,将目标函数值按递减的顺序排序,从而把实函数值转换成从 1 到 $S(S$ 为种群大小)的自然数作为不确定推理的输入. 目标函数的模糊变量“小”采用线性隶属函数,使隶属度直接与函数值的排列顺序成正比,即最佳位置有最大隶属度值为 $u_{max}=1.0$,最差位置有最小隶属度 $u_{min}=0.011\ 1$,在其他的位置 $u<1.0$,可表示为

$$u_i = u_{max} - \frac{S - I_i}{S - 1}(u_{max} - u_{min}), \quad i = 1, 2, \cdots, S, \tag{7}$$

$$u_{i,j} = \text{rand}(u_i, 1), \quad j = 1, 2, \cdots, D. \tag{8}$$

式(7),(8)中: u_i 为目标函数值 i 的隶属度; $u_{i,j}$ 为 j 维搜索空间目标函数 i 的隶属度; I_i 为种群函数值按降序排列后 $x_i(t)$ 的序列编号; D 为搜索空间维数.

式(8)是为了模拟人的搜索行为中随机性,函数 $\text{rand}(u_i, 1)$ 是均匀、随机地分布在区间 $[u_i, 1]$ 上的实数. 由不确定性推理条件(式(7),(8))得出隶属度 $u_{i,j}$ 后,可根据不确定推理的行为部分得出步长,即

$$\alpha_{i,j} = \sigma_{i,j} \sqrt{-\ln u_{i,j}}.$$

式中: $\alpha_{i,j}$ 为 j 维搜索空间的搜索步长; $\sigma_{i,j}$ 为高斯隶属函数参数,其值可由 $\sigma_{i,j} = \omega \cdot |(x_{max} - x_{min})|$, $\omega = (T_{max} - t) / T_{max}$ 确定. 其中: x_{min} 和 x_{max} 分别是同一子群中的具有最小和最大函数值的位置; ω 是惯性权值,随着进化代数的增加从 0.9 线性递减至 0.1; t 和 T_{max} 分别为当前迭代次数和最大迭代次数;而函数 $|\cdot|$ 为对输入的每一个元素取绝对值.

综上所述,对 3 种算法的相关参数设置如下:GA 算法的交叉概率和变异概率分别选取为 $p_c=0.2$

和 $p_m=0.9$; PSO 算法的最大、最小权重因子分别为 $\omega_{\max}=0.9, \omega_{\min}=0.4$, 学习因子 $c_1=c_2=1.49445$; SOA 算法最大、最小隶属度值 $u_{\max}=1.0, u_{\min}=0.011$, 权值最大值、最小值分别为 $\omega_{\max}=0.9, \omega_{\min}=0.1$.

以 MATLAB 为算法执行环境, 通过设置不同种群规模和最大迭代次数, 对 RBF 神经网络的初始参数进行寻优. 分别对每组种群规模和最大迭代次数的 3 种算法进行独立实验 200 次, 并对这 200 次结果中每个算法执行的目标函数最小值、目标函数最大值、目标函数平均值, 以及算法的平均计算时间进行列举和对比, 结果如表 2 所示.

表 2 3 种算法的寻优对比结果
Tab. 2 Optimization comparison results of three algorithms

种群规模	最大迭代次数	算法类型	目标函数最小值	目标函数最大值	目标函数平均值	平均计算时间/s
5	50	GA	290.059 7	604.755 8	483.852 1	3.645 0
		PSO	270.006 0	517.680 3	325.108 1	3.955 3
		SOA	192.678 1	425.809 9	319.865 9	10.570 3
5	100	GA	259.319 2	564.775 7	415.558 6	7.120 4
		PSO	201.791 9	407.500 8	343.551 3	7.054 2
		SOA	169.692 8	459.543 4	271.548 8	19.726 0
5	200	GA	230.334 2	636.550 4	400.250 6	13.684 5
		PSO	195.590 5	558.562 3	312.459 0	13.747 5
		SOA	90.867 8	358.808 5	181.467 8	39.486 2
20	50	GA	233.941 2	485.439 5	312.257 8	13.408 9
		PSO	97.482 1	280.204 4	152.418 5	13.514 0
		SOA	64.031 5	310.666 9	136.746 3	38.688 6
20	100	GA	211.509 6	348.803 7	270.441 3	26.177 4
		PSO	50.680 2	270.702 0	158.861 3	26.444 8
		SOA	43.326 0	246.280 4	137.683 3	78.283 2
20	200	GA	187.784 8	311.252 7	242.652 7	52.056 8
		PSO	120.193 7	291.193 7	202.305 6	51.071 6
		SOA	40.038 2	219.195 2	143.188 6	152.342 8
35	50	GA	232.155 8	390.525 3	271.901 1	23.041 2
		PSO	39.067 3	228.837 9	88.349 6	22.275 0
		SOA	75.055 4	189.736 3	79.415 5	64.628 6
35	100	GA	242.498 8	349.556 4	285.234 5	44.388 8
		PSO	30.202 7	225.978 6	91.602 7	44.193 6
		SOA	44.852 1	144.231 1	106.237 0	129.203 1
35	200	GA	129.047 1	261.145 4	207.210 2	86.398 3
		PSO	34.763 5	180.817 4	81.593 9	88.164 0
		SOA	34.019 9	147.929 3	71.708 1	258.688 4
:	:	:	:	:	:	:

表 2 是 3 种算法的寻优结果对比. 其中, 平均计算时间越小, 表明算法的求解速度越快; 目标函数平均值越小, 表明算法的寻优能力越强; 目标函数最小值与目标函数最大值之间相差越小, 表明算法的寻优能力越稳定. 由表 2 可知: 随着对种群规模和最大迭代次数的增加, 3 种算法的寻优效果均得到增强, 但当种群规模达到一定范围时, 寻优效果增强的幅度就比较弱.

在不同种群规模和最大迭代次数组合的情况下, 与 GA 算法和 PSO 算法这两种算法相比, SOA 算法的寻优能力均比较强, 且寻优能力相对比较稳定, 强健和稳定的寻优能力导致的缺点就是求解速度相对较慢; 种群规模和最大迭代次数越大, 3 种算法的寻优能力均变得增强和稳定, 但 SOA 算法的寻优能力始终较其他两种算法表现显著; 而当种群规模大到一定值后, 3 种算法的寻优能力的增强幅度就比较缓慢, 所以选择种群规模 35 和最大迭代次数 200 更能做进一步的迭代曲线对比. 随机运行 3 种算法的迭代寻优结果, 如图 4 所示.

由图 4 可知: GA 算法从第 70 代以后, 后期适应度值(目标函数值)一直保持在 175 左右, 说明该算法后期陷入了局部最优解, 导致寻优能力大大下降; PSO 算法从第 10 代开始, 适应度值就维持在 50, 很

明显前期出现了“早熟”现象,导致后期寻优能力不再增强;而采用 SOA 算法相比于前两种算法,适应度值从最大值 450 逐渐减少到 45 以下,寻优能力变化很稳定,且在 200 代时适应度值最小,说明 SOA 算法后期容易搜索到全局最优解,具有更好的收敛精度和寻优性能。

将优化所寻得的基宽向量 b 、中心矢量 c 和网络权值 ω 共 12 个值,代入 RBF 神经网络的逼近结构中,可得到 3 种算法对应的逼近图,分别如图 5~7 所示。由图 5~7 可以看出:应用 3 种智能算法下的 RBF 逼近系统均表现出平稳逼近的效果,而三者逼近性能对比并不明显。

将 3 种算法产生的逼近误差做出进一步的对比,结果如图 8 所示。由图 8 可知:采用 GA 算法和 PSO 算法逼近的误差后期均发生了跳变,导致逼近不够稳定;而采用 SOA 算法逼近的误差一直稳定在零的附近。所以,采用 SOA 算法优化后的参数应用到 RBF 神经网络中,系统更具有精度高、逼近误差小、平稳时间短及超调量小等优点。




图 4 3 种算法下的寻优对比图

Fig. 4 Optimization comparison chart of three algorithms




图 5 基于 GA 算法的 RBF 网络逼近
Fig. 5 RBF network approximation based on GA algorithm




图 6 基于 PSO 算法的 RBF 网络逼近
Fig. 6 RBF network approximation based on PSO algorithm




图 7 基于 SOA 算法的 RBF 网络逼近
Fig. 7 RBF network approximation based on SOA algorithm




图 8 3 种算法的逼近误差对比
Fig. 8 Comparison of three algorithms approximation error

综上所述,在采用 GA 算法、PSO 算法和 SOA 算法这 3 种算法优化 RBF 神经网络的初始参数时,如果对算法相关参数选取的都比较得当,且系统对算法执行时间的长短要求不高,将 SOA 算法应用到 RBF 神经网络的参数整定中,具有更好的效果。

4 结束语

为了改善和优化 RBF 神经网络结构中的初始参数,提出一种基于人群搜索算法的 RBF 神经网络参数整定方法,并将其与遗传算法和粒子群算法对 RBF 神经网络参数的整定条件进行对比。结果可以

看出:将人群搜索算法应用到 RBF 神经网络结构中,可以有效地改善系统的收敛精度,从而验证了该算法的优越性.

参考文献:

- [1] 樊兆峰,马小平,邵晓根.非线性系统 RBF 神经网络多步预测控制[J].控制与决策,2014,29(7):1274-1278. DOI:10.13195/j.kzyjc.2013.0518.
- [2] MOODY J,DARKEN C. Fast learning in networks of locally-tuned processing units[J]. Neural Computation,1989,1:281-294. DOI:10.1162/neco.1989.1.2.281.
- [3] 张森.基于径向基函数网络的 MH/Ni 电池荷电状态预测[J].化工学报,2006,57(9):2162-2166. DOI:10.3321/j.issn:0438-1157.2006.09.029.
- [4] 罗玉涛,张保觉,赵克刚.基于神经网络的动力电池组 SOC 辨识方法[J].电源技术,2007,33(11):914-917. DOI:10.3969/j.issn.1002-087X.2007.11.019.
- [5] 吕程,刘子云,刘子建,等.广义径向基函数神经网络在热误差建模中的应用[J].光学精密工程,2015,23(6):1705-1713. DOI:10.3788/OPE.20152306.1705.
- [6] 吴玉香,张景,王聪.基于径向基函数神经网络的转子系统裂纹故障诊断[J].控制理论与应用,2014,31(5):1061-1068. DOI:10.7641/CTA.2014.30965.
- [7] 韩红桂,乔俊飞,薄迎春.基于信息强度的 RBF 神经网络结构设计研究[J].自动化学报,2012,38(7):1083-1090.
- [8] 崔志强,刘吉臻,刘金琨.基于微分器的燃料-汽压系统直接神经网络控制[J].动力工程学报,2012,32(6):445-449,493. DOI:10.3969/j.issn.1674-7607.2012.06.005.
- [9] 胡云安,程春华,邹强,等.非仿射纯反馈系统的间接自适应神经网络控制[J].控制理论与应用,2014,31(4):467-478. DOI:10.7641/CTA.2014.30814.
- [10] 高飞. MATLAB 智能算法超级学习手册[M].北京:人民邮电出版社,2014.
- [11] 马超,邓超,熊尧,等.一种基于混合遗传和粒子群的智能优化算法[J].计算机研究与发展,2013,50(11):2278-2286.
- [12] DAI Chaohua,ZHU Yunfang,CHEN Weirong. Seeker optimization algorithm[C]//International Conference on Computational Intelligence and Security. Guangzhou: IEEE Press,2006:167-176. DOI:10.1109/ICCIAS.2006.294126.
- [13] KETABI A,NAVARDI M J. Optimization shape of variable-capacitance micromotor using seeker optimization algorithm[J]. Journal of Electrical and Technology,2012,7(2):212-220. DOI:10.5370/JEET.2012.7.2.212.
- [14] KUMAR D,SAMANTARAY S R. Design of an advanced electric power distribution systems using seeker optimization algorithm[J]. International Journal of Electrical Power and Energy Systems,2014,63(63):196-217. DOI:10.1016/j.ijepes.2014.05.073.
- [15] LIN Jian,CHEN Chang. Parameter estimation of chaotic systems by an oppositional seeker optimization algorithm[J]. Nonlinear Dynamics,2014,76(1):509-517. DOI:10.1109/TCPMT.2014.2316301.
- [16] 楼旭伟,楼辉波,朱剑锋.基于遗传算法径向基神经网络的交通流预测[J].中国科技论文,2013,8(11):1141-1144. DOI:10.3969/j.issn.2095-2783.2013.11.015.
- [17] 龙亿,杜志江,王伟东. GA 优化的 RBF 神经网络外骨骼灵敏度放大控制[J].哈尔滨工业大学学报,2015,47(7):26-30. DOI:10.11918/j.issn.0367-6234.2015.07.003.
- [18] 王雅,孙耀宁,李瑞国.基于粒子群算法的 RBF 神经网络齿轮磨损预测[J].机车与液压,2016,44(3):183-187. DOI:10.3969/j.issn.1001-3881.2016.03.046.

(责任编辑:钱筠 英文审校:吴逢铁)