

# 基于混沌免疫优化 RBF 网络的遥感水深反演

朱 玉, 赵 卿, 周兴东

(江苏师范大学测绘学院, 江苏 徐州 221116)

**摘 要:** BP 网络学习算法存在收敛速度慢、易陷入局部极小的缺点。为此, 提出一种基于混沌免疫优化径向基函数(RBF)网络的遥感水深反演模型。介绍水深遥感反演原理, 利用混沌免疫优化算法对 RBF 网络的中心向量及连接权值进行优化, 并将优化的 RBF 网络应用于遥感水深反演。实验结果表明, 该模型反演水深和实测水深之间的平均绝对误差为 0.436 7 m, 平均相对误差为 8.91%, 均方根误差为 0.563 5 m, 具有较好的非线性映射能力和泛化能力。

**关键词:** 水深遥感; 混沌免疫优化算法; 径向基函数; 反演模型; 泛化能力

## Remote Sensing Water Depth Inversion Based on Chaotic Immune Optimization RBF Network

ZHU Yu, ZHAO Qing, ZHOU Xing-dong

(School of Geodesy and Geomatics, Jiangsu Normal University, Xuzhou 221116, China)

**【Abstract】** BP network learning algorithm has the shortcomings of slow convergence speed, easy to fall into local minimum. In order to solve this problem, this paper presents a remote sensing water depth inversion model based on chaotic immune optimization Radial Basis Function(RBF) network. In the model, it introduces the water depth remote sensing inversion principle, the RBF network center vector and weights are optimized by using Chaotic Immune Optimization Algorithm(CIOA), and the CIOA RBF network model are applied in the comparing experiments of remote sensing water depth inversion. Experimental results show that the average absolute error of this model between the inversion water depth and measured water depth is 0.436 7 m, the average relative error is 8.91%, the mean square root error is 0.563 5 m, this model has good nonlinear mapping ability and generalization ability.

**【Key words】** water depth remote sensing; Chaotic Immune Optimization Algorithm(CIOA); Radial Basis Function(RBF); inversion model; generalization ability

DOI: 10.3969/j.issn.1000-3428.2013.05.041

### 1 概述

20 世纪 70 年代开始利用卫星多光谱遥感数据反演水下地形。随着遥感技术的发展, 利用多光谱遥感数据进行水深反演已经从定性分析发展到了定量计算阶段<sup>[1]</sup>。遥感水深反演探测水深是一种间接方法, 它主要应用水体对光的反射及自身辐射特性, 通过对卫星传感器接收的数据进行信息分离, 结合实测水深数据进行水深反演。目前, 在国内外水深遥感反演中, 主要有理论解释模型、半理论半经验模型和统计相关模型等形式<sup>[2]</sup>。国内外学者在水深遥感领域做了大量的研究, 提出了众多形式的反演模型, 由于遥感水深反演是一个非线性过程, 影响因素较多, 且很难有固定的模型或者模型参数实现遥感的水深反演<sup>[3]</sup>。

人工神经网络(Artificial Neural Network, ANN)具有较好的非线性逼近能力, 近年来, 在遥感水深反演中已有一定的应用, 其中, 应用较多的是 BP 网络<sup>[4]</sup>。BP 网络学习是典型的有导师学习, 传统 BP 网络学习算法的优点是寻优具有精确性和自学习能力, 但同时存在收敛速度慢、易陷入局部极小等缺点<sup>[5]</sup>。为此, 本文提出一种基于混沌免疫优化算法(Chaotic Immune Optimization Algorithm, CIOA)的径向基函数(Radial Basis Function, RBF)网络遥感水深反演模型, 并将反演结果与实测值进行比较。

### 2 水深遥感反演

在光进入水体后, 主要受水分子的散射作用、水体中悬浮物质的反射及水体传播中的自身衰减 3 种衰减影响。

**基金项目:** 国家自然科学基金资助项目(40771143); 江苏师范大学博士学位教师科研支持基金资助项目(10XLR24, 10XLR16)

**作者简介:** 朱 玉(1977—), 男, 讲师、博士, 主研方向: 模式识别; 赵 卿, 讲师、博士; 周兴东, 教授、博士

**收稿日期:** 2012-05-10 **修回日期:** 2012-07-17 **E-mail:** zhuyuj@139.com

光在水体中随着水深的变化按指数形式衰减，衰减系数  $\alpha$  和水深  $D$  之间的关系可简单表示为： $\alpha=1/D$ ，衰减系数与波长的关系如图 1 所示。

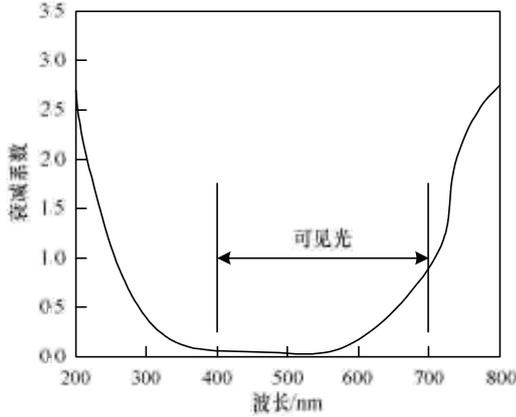


图 1 衰减系数与波长的关系

由图 1 可知，衰减系数最低的波段在蓝色(450 nm)至黄色(600 nm)之间，因此，在水深反演进行遥感数据波段选择时，应尽量选择这个范围内的波段进行反演。

### 3 混沌免疫优化算法

混沌免疫优化算法流程如图 2 所示。

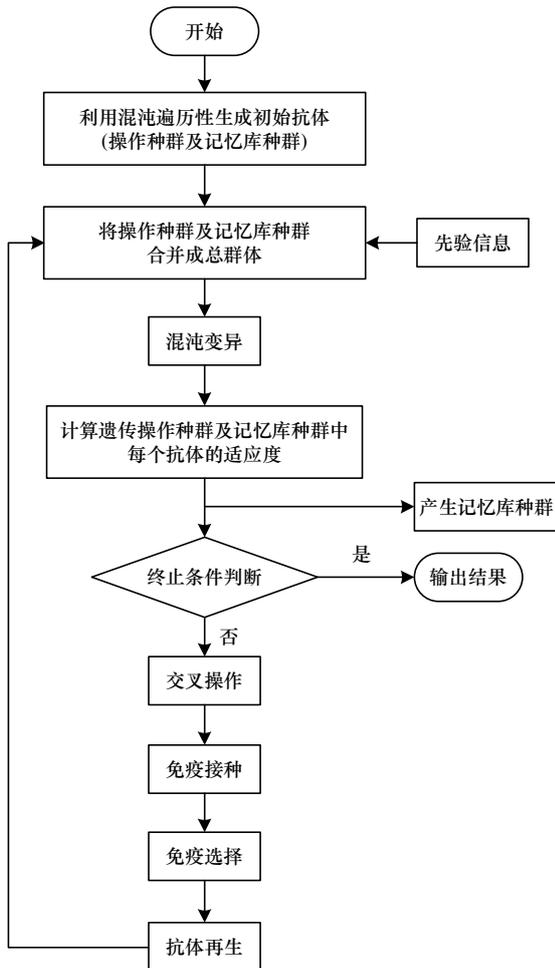


图 2 混沌免疫优化算法流程

人工免疫算法(Artificial Immune Algorithm, AIA)是借鉴生命科学中的免疫理论发展起来的一种新型优化算法<sup>[6]</sup>。AIA 通过利用待求问题中的一些特征信息，实现对优化过程中产生的“退化”现象的抑制。它充分利用了进化过程中每一代最佳个体及确定性变化基础上随机搜索的特性，在一定程度上减少了进化过程中的随机影响因素，克服了未成熟收敛现象。但是 AIA 在小区间内搜索到最优解(满意解)的能力还有待提高<sup>[7]</sup>。

混沌是指发生在确定性系统中的一种貌似随机的不规则运动，但实际上混沌运动具有伪随机性、遍历性、规律性等特点，使混沌搜索能在一定范围内按照自身规律不重复地遍历每一个状态<sup>[8-9]</sup>。混沌优化算法利用混沌的上述特点，首先在局部范围内改变优化变量为混沌变量，并通过改变混沌变量准则检查每个点在整个解空间的变化，以寻找更优的点为目前最佳的解决方案。然后，它以当前最佳方案为核心，通过扰动去寻找全局范围内满足要求的最优解(满意解)。

本文结合免疫算法和混沌优化各自的寻优优势，提出混沌免疫优化算法，并将其应用到 RBF 网络优化中，以实现更优的遥感水深反演。混沌免疫优化算法的基本思想是：在免疫进化的过程中引入混沌寻优方法，改善免疫算法的寻优模式，具有较高的收敛速度，能够避免算法陷入局部最优。

#### 3.1 初始抗体群的产生

利用混沌序列产生初始抗体的步骤如下：

(1)Logistic 混沌映射具有计算量小、使用方便的特点，所以，首先采用 Logistic 映射(式(1))产生混沌序列，再将生成的混沌序列从[0,1]混沌空间映射到系统状态空间，使生成的混沌序列均匀地分布在状态空间。

$$\beta_i^{u+1} = \mu_i \beta_i^u (1 - \beta_i^u) \tag{1}$$

其中， $i=1,2,\dots,k$  表示混沌变量的序号； $u=0,1,\dots,N$  表示种群序号； $\beta_i$  为混沌变量且  $0 \leq \beta_i \leq 1$ ； $\mu_i$  表示吸引子。

取  $u=0$ ， $\mu_i=4$ ，给式(1)赋  $k$  个具有微小差异的初值，得到  $k$  个混沌变量  $\beta_i^{(1)} (i=1,2,\dots,k)$ ，依次取  $u=1,2,\dots,N$  可得到  $N$  个初始解群。

(2)按式(2)将 Logistic 映射产生的初始抗体群序列从混沌空间映射到原问题的解空间，可得到 CIOA 算法所需要的初始抗体群矩阵  $A = (x_1^0, x_2^0, \dots, x_k^0)^T$ 。

$$x_i^0 = a_i + \beta_i^{u+1} (b_i - a_i) \tag{2}$$

其中， $b_i$ 、 $a_i$  为  $x_i$  的取值上限、下限。

#### 3.2 混沌变异策略

CIOA 算法利用混沌机制对变异算子进行改进，用混沌映射来实现混沌变异操作，具体过程如下：将抗体  $v$  映射到[0,1]空间，并作为混沌初值  $\beta_i^0$  代入式(1)，再进行  $k$  次迭代，得到混沌向量  $\beta_i^k$ ，并按式(3)计算变异后的混沌向量

$\beta_i^{k'}$ , 最后再将  $\beta_i^{k'}$  映射到解空间, 完成混沌变异过程, 得到变异后的抗体  $v'$ 。

$$\beta_i^{k'} = (1 - c_v \alpha) \hat{\beta}_i + \alpha \beta_i^k \quad (3)$$

其中,  $0 < \alpha < 1$  为调节系数, 随着迭代次数自适应变化;  $\hat{\beta}_i$  为当前最优值;  $c_v$  为抗体浓度, 为群体中具有最大适应度或近似最大适应度的抗体数与抗体总数的比率。由式(3)可知, 由于混沌的初值敏感性,  $\beta_i^0$  的微小差异可能导致  $\beta_i^k$  的极大差异, 从而达到增加变异范围、优化变异效果的目的。同时, 如果抗体浓度越大, 其搜索范围也就越大, 在进化后期, 群体结构将趋于一致, 变异起到主导作用, 变异范围增大, 易跳出局部最优。

### 3.3 免疫记忆

免疫记忆主要是依据抗体的适应度(抗体和抗原之间的亲和力, 即抗体和抗原之间的相似程度)实现。首先按式(4)计算抗体的适应度, 按照适应度大小对抗体排序, 取适应度大的  $p$  个抗体作为记忆细胞放入记忆细胞库, 记忆细胞规模  $p$  的取值可动态变化, 如果  $p=1$ , 记忆细胞即为待求问题的最优解。通过免疫记忆操作, 可以充分利用个体优势对群体进化施加影响, 加快算法的收敛速度。

$$f(v_i) = \frac{1}{k} \sqrt{\sum_{i=1}^k (ag_i - v_i)^2} \quad (4)$$

### 3.4 免疫接种

在免疫进化过程中, 较优个体和全局最优解之间的距离一般要小于其他个体和全局最优之间的距离, 考虑与较优个体之间距离较小的个体可能具有较高的适应度, 因此, 可对记忆细胞按下式进行免疫接种:

$$v' = v_m + \sigma N(0,1) \quad (5)$$

其中,  $v'$  为接种的个体;  $v_m$  为记忆细胞;  $N(0,1)$  为产生的服从标准正态分布的随机数;  $\sigma$  为可调参数。通过接种操作, 可以使得与最优抗体类似的个体大量繁殖, 加大对最优个体附近解空间的投点密度, 提高算法的搜索效率和进化速度。

### 3.5 免疫选择

为了提高 CIOA 的效率, 采用下式计算抗体被选择进入下一代的期望值:

$$E(v_i) = \frac{f(v_i)}{C(v_i)} \quad (6)$$

其中,  $f(v_i)$  为抗体适应度;  $C(v_i)$  为抗体浓度。

免疫选择的目的是通过期望值控制抗体的浓度和多样性, 这样适应度高的抗体会被选择来再生, 而浓度高的抗体将被抑制。如果抗体的期望值过低, 说明抗体可能出现了退化, 因此, 一般选择父代抗体代替该抗体进入下一代。在经过免疫选择后, 再对式(1)的初值作微小变化, 进行抗体再生, 产生新的混沌序列补足个体数目。

## 4 基于 CIOA 优化的 RBF 网络

### 4.1 RBF 网络

RBF 网络源于高维空间的多变量函数的插值理论, 其隐含层的转换函数采用了局部响应的高斯函数, 可以以任意精度逼近任何连续函数<sup>[10]</sup>。RBF 网络是一种前馈神经网络, 一般分为 3 层: 第 1 层为输入层; 第 2 层是隐含层; 第 3 层是输出层, 如图 3 所示。

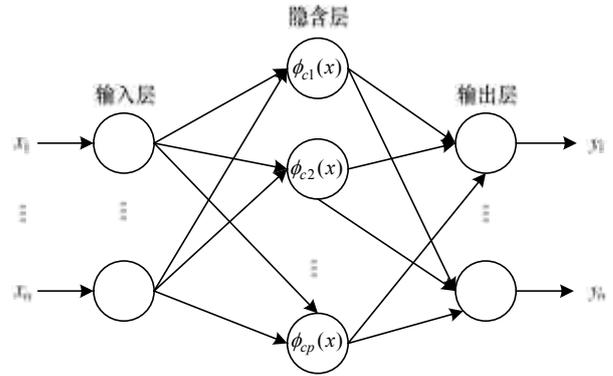


图 3 RBF 网络拓扑结构

在图 3 中,  $(x_1, x_2, \dots, x_n)$  为输入向量;  $(y_1, y_2, \dots, y_m)$  为输出向量; 输入层节点数为  $n$ ; 隐含层节点数为  $p$ ; 输出层节点数为  $m$ 。

RBF 网络的基本思想是: 用 RBF 作为隐单元的“基”构成隐含层空间, 将输入矢量直接(即不需要通过权连接)映射到隐空间, 当 RBF 的中心点确定后, 这种映射关系即可确定。另外隐含层空间到输出空间的映射是线性的, 即网络的输出是隐单元输出的线性加权和(权为 RBF 网络的可调参数)。RBF 网络由输入到输出的映射是非线性的, 网络输出对可调参数是线性的, 网络的权可利用线性方程组直接求出, 这样可加快网络的学习速度并可避免学习陷入局部极小问题。

为了提高 RBF 网络的性能, 网络的设计关键在于学习算法的设计, 网络学习算法设计的关键就在于隐层中心点及隐层节点数的确定<sup>[11]</sup>。目前, 在 RBF 网络中隐层中心确定最常用的方法是 K-means 算法, 但是 K-means 算法使用中最大的局限性是需要先根据先验知识确定中心向量个数(在 RBF 网络中, 中心向量的个数是很难事先确定的), 且其对初值敏感, 因此, 极大地限制了 RBF 网络的实际应用。为此, 本文将提出的混沌免疫优化算法引入到 RBF 网络设计中, 利用 CIOA 对网络的中心向量进行优化, 进而实现网络权值等参数的优化。

### 4.2 基于 CIOA 优化的 RBF 网络算法

首先利用 CIOA 算法对输入样本点进行处理, 根据处理后获得的特征数据确定 RBF 网络的隐层中心和隐层个数, 由隐层中心值, 再利用一种改进的最小均方(Least Mean Square, LMS)算法求出隐层到输出层的优化权值。基于 CIOA 优化的 RBF 网络算法的流程如图 4 所示。

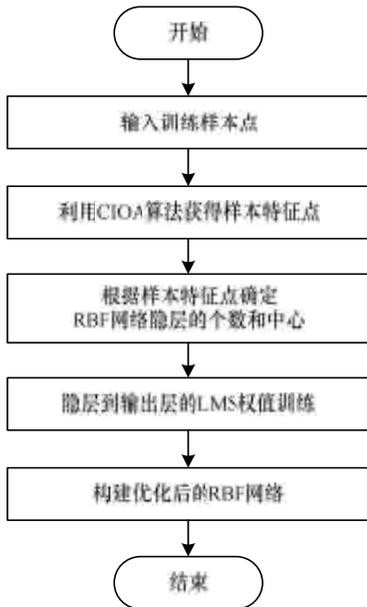


图4 CIOA 优化 RBF 网络算法流程

具体步骤如下:

(1)初始化过程: 根据输入的训练样本点, 采用式(1)产生含有  $N$  个实数的初始混沌序列, 然后将初始混沌序列按式(2)从混沌空间映射到原问题的解空间, 并进行编码, 可得到混沌免疫优化算法所需要的初始抗体群  $C_k$  ( $C_k$  由 2 个部分构成, 即操作种群  $A_k$  及记忆库种群  $B_k$ ), 令  $k=0$ 。  $C_k$  中的个体采用两阶式编码结构进行编码。两阶式编码结构主要由二级基因构成, 第 1 级基因采用二进制编码, 用“0”和“1”分别表示 RBF 网络所对应的隐节点径向基函数处于休眠和激活状态; 当隐节点径向基函数处于激活状态时, 第 2 级基因进行编码, 采用十进制编码, 每一位代表一种网络参数(中心点、宽度等)。设定初始化的隐层神经元最大个数  $Th_{term}$ 。

(2)利用混沌免疫优化算法计算出优化 RBF 网络的隐层个数和中心。

(3)隐层到输出层权值的训练: 采用可变速率的 LMS 算法, 通常在 LMS 算法中, 学习率参数在计算过程中保持不变, 导致收敛速度较慢。所以, 在网络自适应的训练早期阶段, 即迭代次数相对搜寻时间常数较小时, 学习率参数近似为一常数, 然后, 当迭代次数比搜寻时间常数大时, 学习率参数自适应改变。此时, 可变速率的 LMS 算法以一个传统的随机逼近算法运行, 且权值收敛到最优值。

(4)优化径向基函数网络构建、训练及遥感水深反演应用。

## 5 实验结果与分析

### 5.1 数据预处理

遥感数据采用 Landsat-7 淮河安徽省临淮岗上段 ETM+ 卫星遥感影像, 成像时间为 2008 年 5 月 20 日, 水深数据为 2008 年 6 月 7 日实测数据 86 个, 采用 WGS-84 坐标系,

研究区实测水深点示意图如图 5 所示。

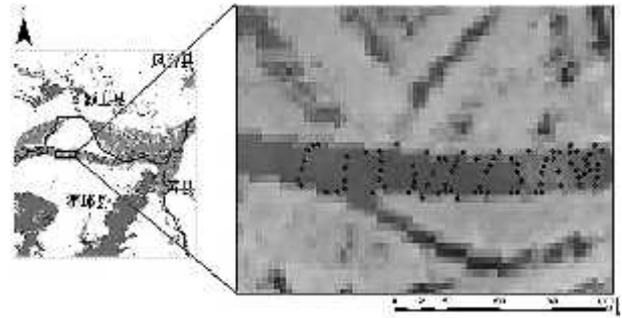


图5 研究区实测水深点示意图

首先对数据进行几何校正、辐射校正等预处理, 在预处理的基础上, 对实测水深值和波段及波段组合像元反射率值进行相关分析, 波段反射率与水深值的相关系数如表 1 所示, 其中, 相关系数为负数表示一个变量的增加可能引起另一个变量的减少。

表1 波段反射率与水深值的相关系数

波段	相关系数
ETM+1	0.418
ETM+2	0.517
ETM+3	0.490
ETM+4	-0.742
ETM+4/ETM+3	-0.743
ETM+4/ETM+2	-0.754
ETM+4/ETM+1	-0.738
ETM+3/ETM+2	0.616

由表 1 可知, 某些波段值与水深的变化有较强的相关性, ETM+4、ETM+4/ETM+3、ETM+4/ETM+2 及 ETM+4/ETM+1 与水深值的相关系数较大, 相关性较强, 适用于模型的建立。

### 5.2 反演结果分析

选取 ETM+1、ETM+2、ETM+3、ETM+4 波段及 ETM+4/ETM+3、ETM+4/ETM+2、ETM+4/ETM+1 波段比值组合作为 CIOA 优化 RBF 网络学习的输入样本, 反演的水深值作为网络的期望输出, 即网络有 6 个输入节点、1 个输出节点。在基于 CIOA 的 RBF 网络学习算法中, 取群体规模为 100, 记忆库种群大小为 10,  $\sigma=0.6$ , 算法进化最大迭代代数为 200。

利用保留的未参加模型训练的 17 个验证样本对模型进行精度及误差计算, 将反演水深和实测值进行比较如表 2 所示, 结果表明, 反演水深的最大、最小绝对误差分别为 0.952 8 m、0.018 9 m; 最大、最小相对误差为 18.77%、0.49%, 说明预测结果有一定的波动, 但是验证数据的平均绝对误差为 0.436 7 m, 平均相对误差为 8.91%, 说明模型的反演精度较高。

表2 反演水深和实测水深的对比

编号	实测水深/m	反演水深/m	绝对误差/m	相对误差/(%)
1	6.597	5.826 4	0.770 6	11.68
2	6.295	5.398 5	0.896 5	14.24
3	6.143	5.558 3	0.584 7	9.52
4	6.133	5.685 5	0.447 5	7.30
5	6.006	5.053 2	0.952 8	15.86
6	5.942	5.694 4	0.247 6	4.17
7	5.861	5.597 1	0.263 9	4.50
8	5.762	5.421 5	0.340 5	5.91
9	5.677	4.787 3	0.889 7	15.67
10	5.573	5.405 2	0.167 8	3.01
11	4.236	5.031 0	0.795 0	18.77
12	4.188	3.989 1	0.198 9	4.75
13	4.123	4.205 5	0.082 5	2.00
14	3.819	3.800 1	0.018 9	0.49
15	3.318	3.256 4	0.061 6	1.86
16	2.256	1.883 5	0.372 5	16.51
17	2.169	1.835 7	0.333 3	15.37

为进一步表明模型的反演精度及泛化能力, 得到相关系数为 0.892 6、均方根误差为 0.563 5 和绝对平均百分比误差为 10.61%, 相关系数表示 CIOA 优化 RBF 网络的反演水深值与实际水深值的测定系数, 相关系数越接近 1 时, 表示反演水深值与实际水深值相关性越好, 当相关系数为 0.892 6 时说明模型有较好的反演能力; 均方根误差表示 CIOA 优化 RBF 网络模型反演的水深值与实测平均水深值的偏差, 均方根误差和绝对平均百分比误差能很好地表示模型的反演精度。可以看出, CIOA 优化 RBF 网络模型能较好地进行水深反演, 具有较好的非线性映射能力和泛化能力。

## 6 结束语

本文提出一种基于混沌免疫优化 RBF 网络的遥感水深

反演模型。利用 CIOA 优化 RBF 网络, 基于波段及波段组合像元反射率值, 建立了遥感水深的反演模型。实验结果表明, 该模型不仅反演精度较高, 而且具有较好的泛化能力。但模型的平均绝对误差较大, 今后将对此进行改进。

### 参考文献

- [1] 徐升, 张鹰. 长江口水域多光谱遥感水深反演模型研究[J]. 地理与地理信息科学, 2006, 22(3): 48-52.
- [2] 王艳姣, 董文杰. 水深可见光遥感方法研究进展[J]. 海洋通报, 2007, 26(5): 92-101.
- [3] 闫峰, 王艳姣. 基于泥沙因子的水深遥感反演模型[J]. 湖泊科学, 2008, 20(5): 655-661.
- [4] 郭小龙, 郭兵, 沈艳. 改进 BP 神经网络在软件能耗分析中的应用[J]. 计算机工程, 2012, 38(10): 185-187.
- [5] 李铁芳. 卫星海洋遥感信息提取和应用[M]. 北京: 海洋出版社, 1990.
- [6] 肖人彬, 王磊. 人工免疫系统: 原理、模型、分析及展望[J]. 计算机学报, 2002, 25(12): 1281-1293.
- [7] Jiao Licheng, Wang Lei. A Novel Genetic Algorithm Based ODS Immunity[J]. IEEE Transactions on Systems, Man, and Cybernetics, Part A: Systems and Humans, 2000, 30(5): 552-561.
- [8] 杨久俊, 邓辉文, 滕姿. 基于混沌免疫进化算法的聚类算法分析[J]. 计算机科学, 2008, 35(8): 154-157.
- [9] 张楠. 人工免疫系统的混沌机制及在网络入侵检测中的应用[D]. 成都: 四川大学, 2006.
- [10] Park J, Sandberg I W. Universal Approximation Using Radial-basis-function Networks[J]. Neural Computation, 1991, 3(2): 246-257.
- [11] 颜学明, 杨凌霄, 葛红. 人工免疫网络算法与 RBF 网络结合的应用研究[J]. 计算机科学, 2011, 38(B10): 169-171, 174.

编辑 刘冰

(上接第 186 页)

- [11] Jeffrey D, Ghemawat S. MapReduce: Simplified Data Processing on Large Clusters[C]//Proc. of the 6th Symposium on Operating System Design and Implementation. San Francisco, USA: [s. n.], 2004.
- [12] Bratton D, Kennedy J. Defining a Standard for Particle Swarm Optimization[C]//Proc. of IEEE Swarm Intelligence Symposium. Honolulu, USA: [s. n.], 2007.
- [13] Ali S, Siegel H J, Maheswaran M, et al. Representing Task and Machine Heterogeneities for Heterogeneous Computing Systems[J]. Journal of Science and Engineering, 2000, 3(3): 195-207.
- [14] 李宁, 孙德宝, 邹彤, 等. 基于差分方程的 PSO 算法粒子运动轨迹分析[J]. 计算机学报, 2006, 29(11): 2052-2061.
- [15] Ratnaweera A, Halgamuge S K, Watson H C. Self-organizing Hierarchical Particle Swarm Optimizer with Time-varying Acceleration Coefficients[J]. IEEE Transactions on Evolutionary Computation, 2004, 8(3): 240-255.
- [16] Calheiros R N, Ranjan R, Beloglazov A, et al. CloudSim: A Novel Framework for Modeling and Simulation of Cloud Computing Infrastructures and Services[EB/OL]. (2010-09-21). <http://www.clound-bus.org/reports/CloudSim-ICPP2009.pdf>.
- [17] 李晓东, 张庆红, 叶瑾琳. 基于仿真的优化的粒子群算法参数选取研究[J]. 计算机工程与应用, 2011, 47(33): 30-35.

编辑 刘冰



