

基于AHP-RBF的Swift云存储负载预测

谭 乾¹, 江 弋¹, 林 凡²

TAN Qian¹, JIANG Yi¹, LIN Fan²

1. 厦门大学 信息科学与技术学院, 福建 厦门 361005

2. 厦门大学 软件学院, 福建 厦门 361005

1. School of Information Science and Technology, Xiamen University, Xiamen, Fujian 361005, China

2. School of Software, Xiamen University, Xiamen, Fujian 361005, China

TAN Qian, JIANG Yi, LIN Fan. Load prediction of Swift cloud storage based on AHP-RBF. Computer Engineering and Applications, 2014, 50(8): 35-39.

Abstract: Through the study of Proxy Node load factors in Swift cloud storage, a method which combines Analytic Hierarchy Process(AHP) and Hybrid Hierarchical Genetic Algorithm for training of Radial Basis Function Neural Network(HHGA-RBFNN) is proposed to predict Swift cloud storage load. This paper uses AHP to construct load hierarchy model of the system for raising comprehensive accuracy of load prediction of the system, designs RBFNN prediction model, and uses hybrid hierarchical genetic algorithm to train RBFNN's parameters and configuration. From the experimental results, this method is effective, and can be a selection for Swift cloud system load balancing decision.

Key words: Swift; hybrid hierarchical genetic algorithm; Radial Basis Function(RBF) neural networks; Analytic Hierarchy Process(AHP); load

摘 要:通过对Swift云存储中Proxy Node的负载因素研究,提出结合层次分析法(AHP)和混合递阶遗传训练的RBF神经网络实现对Swift云存储负载情况的预测,其中使用AHP构造对云存储系统的负载层次化模式,提高负载预测的综合精度,设计了RBF神经网络预测模型,用混合递阶遗传算法(HHGA)确定RBF神经网络的参数和结构。仿真实验结果表明,对Swift云存储负载的预测具有可行性,能为系统动态负载均衡决策提供依据。

关键词:Swift; 混合递阶遗传算法; 径向基函数(RBF)神经网络; 层次分析法; 负载

文献标志码:A **中图分类号:**TP39 **doi:**10.3778/j.issn.1002-8331.1309-0490

1 引言

随着云计算的广泛应用,构建云计算平台的开源项目也在不断增加。像Hadoop、Eucalyptus、CloudStack、OpenStack^[1]等。就目前来看OpenStack是这其中最为火热的开源项目之一。很多国内外大公司对OpenStack表示看好并参与进来,如Intel、IBM、思科、HP等。支持OpenStack的原因主要有其完全开源、良好的设计及社区活跃度高。OpenStack Swift是多租户、强大扩展性、冗余和持久性的对象存储系统,能通过RESTful http API以低代价存储大量非结构化数据,同时还具有无单

点故障优点。到目前为止,OpenStack的最新版本Grizzly已经发布,其设计也更加完善。然而在生产环境中利用OpenStack Swift搭建云存储平台应用^[1],需要设计负载均衡层用来分发存取请求给Proxy Node。因而负载均衡仍是需要解决优化的问题。

目前,动态负载均衡算法较静态负载均衡算法实现复杂度高,需要收集负载信息所用额外开销,但它考虑到集群中每个服务节点的当前状况,能充分发挥各服务节点的处理能力,提高集群系统的吞吐量。如果分配调度得当,付出的额外开销对提高集群系统性能是有必要

基金项目:国家自然科学基金(No.61001143)。

作者简介:谭乾(1987—),男,在读研究生,主要研究领域为移动计算、云存储;江弋(1960—),男,副教授,主要研究方向为数据库、数据挖掘、生物信息学;林凡(1978—),男,助理教授,主要研究方向为云计算、嵌入式。

收稿日期:2013-09-30 **修回日期:**2013-11-21 **文章编号:**1002-8331(2014)08-0035-05

CNKI网络优先出版:2013-12-26, <http://www.cnki.net/kcms/doi/10.3778/j.issn.1002-8331.1309-0490.html>

的。在这其中,服务节点的运行状态是通过各种负载信息来反应的,因而负载的评估决定请求分配算法的性能优劣。

关于负载预测方面的研究,类似应用比较典型的有BP神经网络算法^[2],基于滤波理论预测算法^[3]等等。然而建立一个通用的预测方法来适用各种应用是很难的。不同的应用,由于性质的差异,需要相对应的、合适的预测方法来进行负载预测。以OpenStack Swift带有对Proxy Node监控功能模块的云存储系统(如图1)为基础,针对Proxy Node负载情况,提出结合层次分析法和混合递阶遗传训练的RBF神经网络的Swift云存储负载预测方法。仿真实验表明该预测方法相对预测精度较好,为负载均衡算法提供服务具有可行性。

图1中,在Proxy Node上添加监测模块,能够不间断定时对其收集相应运行状态数据,再用收集到的数据预测其负载情况。负载均衡层得到系统各Proxy Node负载预测结果后,对访问请求做出相应的分发策略。

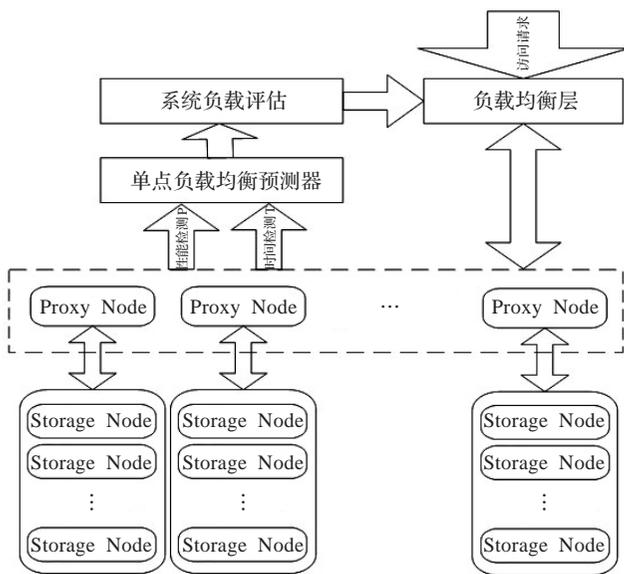


图1 Swift云存储系统

2 层次分析方法

层次分析法(Analytic Hierarchy Process, AHP)是美国运筹学专家Saaty在20世纪70年代中期最先提出的,它是一种有效地处理不易量化变量的多准则决策手段,可以将复杂的问题分解成递阶层次结构,然后在比原问题简单得多的层次上逐步分析;AHP简单明了,将人们的思路数字化、系统化,便于接受并容易计算,并将定性分析与定量分析有机地结合起来,对于解决多层次、多目标的大系统优化问题行之有效。

运用AHP对系统中Proxy Node负载进行评估,得到的评估值作为样本数据训练混合递阶遗传训练的RBF神经网络。AHP应用的具体步骤如下:

(1)建立评估指标体系

在研究影响云存储负载均衡因素的基础上,遵循系统完整性、独立性、可衡量性、简明性、可操作性等原则。根据AHP理论且从Proxy Node负载信息的角度出发,构建了负载均衡评估体系,如图2所示。

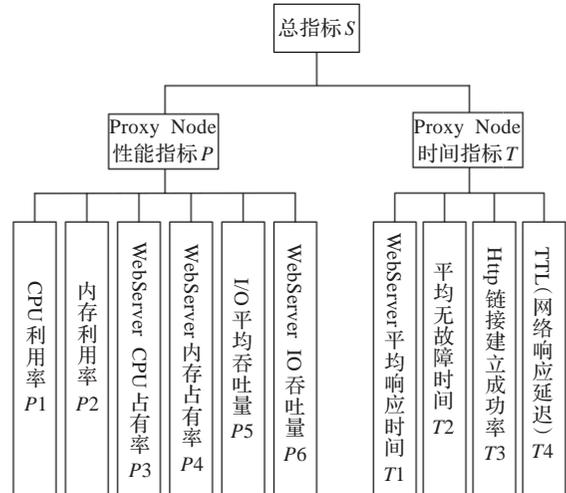


图2 Proxy Node负载的AHP评估体系

通过采集Proxy Node性能指标P的参数数据和时间指标T的参数数据分别评估出指标P和指标T,最终由指标P和指标T的评估值得出总指标S的评估。性能指标P包含CPU利用率P1、内存利用率P2、Web Server CPU占有率P3、Web Server内存占有率P4、I/O平均吞吐量P5、Web Server IO吞吐量P6。时间指标T包含Web Server平均响应时间T1、平均无故障时间T2、HTTP链接建立成功率T3、TTL T4。

(2)构造两两比较判断矩阵

构造判断矩阵是AHP的一个关键步骤。就判断矩阵表示针对上一层某要素而言,评价本层与它有关联的各要素之间的相对优越程度的判断。本文采用多位老师根据指标体系独立构造出相应的判断矩阵,这些矩阵具有AHP中判断矩阵的一般特性,然后利用不同判断矩阵对应元素的几何平均法构造出群决策判断矩阵^[4],因而避免个人构造判断矩阵所具有的很大片面性和主观性。

对于图2中Proxy Node性能指标P,其对应的群决策判断矩阵PD为:

$$PD = \begin{bmatrix} 1 & 2 & 3 & 5 & 3 & 5 \\ 1/2 & 1 & 2 & 4 & 2 & 4 \\ 1/3 & 1/2 & 1 & 3 & 1 & 3 \\ 1/5 & 1/4 & 1/3 & 1 & 1/2 & 1 \\ 1/3 & 1/2 & 1 & 2 & 1 & 2 \\ 1/5 & 1/4 & 1/3 & 1 & 1/2 & 1 \end{bmatrix}$$

Proxy Node时间指标T,其对应的群决策判断矩阵TD为:

$$TD = \begin{bmatrix} 1 & 1/3 & 3 & 2 \\ 3 & 1 & 6 & 5 \\ 1/3 & 1/6 & 1 & 1/2 \\ 1/2 & 1/5 & 2 & 1 \end{bmatrix}$$

总指标对应的群决策判断矩阵 SD 为:

$$SD = \begin{bmatrix} 1 & 3 \\ 1/3 & 1 \end{bmatrix}$$

(3) 相对权重计算及判断矩阵的一致性检验

由 PD 得出其最大特征根 $\lambda_{\max}(PD) = 6.075$, 相对权重向量 (特征向量) $W_{PD} = (0.3709, 0.2380, 0.1452, 0.0607, 0.1244, 0.0607)^T$

$$CI_P = \frac{\lambda_{\max}(PD) - 6}{6 - 1} = 0.0150$$

查RI表知道平均随机一致性指标 RI 值,从而可由下式结果知矩阵 PD 满足一致性:

$$CR_P = \frac{CI_P}{RI} = \frac{0.0150}{1.24} = 0.0122 < 0.1$$

同理,得出 TD 和 SD 各自的特征向量为 $W_{TD} = (0.2220, 0.5743, 0.0773, 0.1264)^T$ 、 $W_{SD} = (0.7500, 0.2500)^T$ 并且都满足一致性。

(4) 计算负载评估值

计算出各因素的相对权重后,负载评估值(总指标)即为递阶推进的参数值与相对权重的加权和。公式如下:

$$S_{load} = \sum V_i \times W_i \quad (1)$$

式中 V_i 为收集到的参数实际数值, W_i 为参数所对应的相对权重。

3 混合递阶遗传训练RBF神经网络的预测模型

3.1 RBF神经网络预测模型

BP神经网络^[5]是用于预测比较多的技术,但是BP网络训练速度比较慢,效率低,并且存在局部最优问题。BP网络的每个权值都影响着网络的输出结果,而在训练时权值都需要通过反向误差传播进行调整,学习速度比较慢。而RBF神经网络^[6-7]在一定程度上克服了这些问题。RBF神经网络可以逼近非线性函数,具有很快的学习和收敛速度,可以处理系统内在的较难解析的规律性,具有实时性等特点,所以RBF网络的用途十分广泛。目前,RBF网络已成功地应用到时间序列分析、非线性函数逼近、模式识别、数据分类、系统建模、控制和故障诊断、信息处理等问题。

高斯函数是比较常用的基函数。基函数表示为:

$$T_i(x) = e^{-\frac{\|x - C_i\|^2}{2\sigma_i^2}}, i = 1, 2, \dots, m \quad (2)$$

式中, $\|x - C_i\|$ 表示 x 与 C_i 之间的欧式距离, $T_i(x)$ 表示第 i 个隐层节点的输出, x 是 n 维的输入向量, m 是隐层神经元个数, C_i 是基函数中心, σ_i 是第 i 个隐层节点的基宽度。隐层的每个神经元节点都有一个径向基函数中心向量 C_i , 该向量和输入样本 x 具有相同的维数, $C_i = [C_{i1}, C_{i2}, \dots, C_{im}]^T, i = 1, 2, \dots, m$, 隐层有 m 个神经元, 则有 m 个这样的中心。

RBF网络的输出层是隐层节点输出的线性组合, 输出为 Y_k :

$$Y_k = \sum_{i=1}^m \omega_{ik} T_i(x), k = 1, 2, \dots, p \quad (3)$$

式(3)中, ω_{ik} 是第 i 个隐层节点到输出层节点的权值, p 是输出层神经元个数。在RBF神经网络中, 隐层节点的输出代表着输入样本 x 离开隐层节点的径向基函数中心 C_i 的程度。由于不存在连接输入节点和隐层节点的权矩阵, 因此隐层的训练任务不是调节权矩阵, 而是为每个隐节点选择其中心向量。网络的输入层实现非线性映射, 输出层实现线性映射。

在基于OpenStack Swift构建的云存储系统中, 如果其负载情况的每次评估都根据AHP计算得出的各级指标权重进行相应的计算与评价, 计算过程比较复杂并且难保证不出错, 没有延展性; 并且AHP判断矩阵的构建主观性较强, 需要一定的经验知识。因此, 将AHP与RBF神经网络有效结合, 使得RBF神经网络通过一定量的训练得出一个具有相关领域专家经验的网络; 当进行新的评价过程时, 只需修改训练成熟网络的输入参数, 就可得出相应的网络输出, 即综合评价价值, 大大减少了复杂的运算过程。根据上面层次分析法部分建立的层级体系, 从Proxy Node收集相应的参数数据及AHP得出数据作为RBF神经网络的数据集, 将其中一部分作为训练集, 剩下的作为测试集, 对RBF神经网络的预测作用进行验证。

构建的RBF预测模型如图3所示。

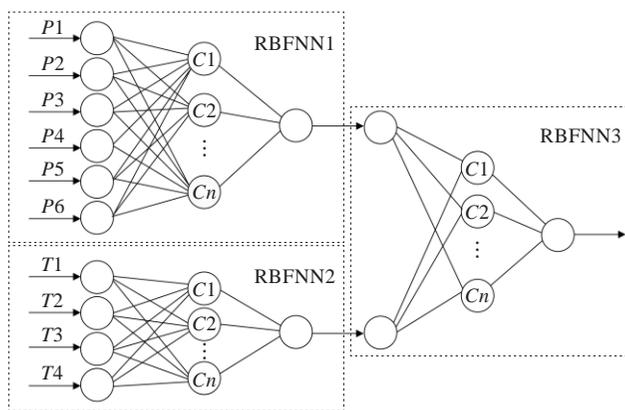


图3 RBF神经网络预测模型

图3中, RBF预测模型由3个RBF神经网络构成, 左上角的RBFNN1输入为 $P_1 P_2 \dots P_6$, 左下角的RBFNN2输入为 $T_1 T_2 \dots T_4$, 这两个RBF神经网络的输出构成右边RBF的输入, 最终由右边的RBFNN3输出最终的预测值。

3.2 混合递阶遗传训练RBF神经网络

遗传算法(Genetic Algorithm, GA)是由美国J.Holland教授在20世纪70年代首先提出, 而后由De Jong、Goldberg

等人归纳总结形成的一类模拟进化算法^[8-10]。主要包括初始化、评价、选择、杂交和变异过程。利用遗传算法来训练相关的RBF网络^[11],既保留了神经网络的学习能力和鲁棒性,又有遗传算法的全局寻优能力。递阶遗传算法(HGA)是根据生物染色体的层次结构提出的^[12],染色体有两部分构成:控制基因和参数基因。虽然基于递阶遗传算法能够确定RBF神经网络的参数和结构,但是网络学习收敛速度较慢、效率低^[13]。

因而,选择采用混合递阶遗传算法(HHGA)训练RBF神经网络,其将递阶遗传算法与递推最小二乘法相结合。利用递阶遗传算法只确定RBF神经网络的结构、隐层节点的中心和宽度,同时用递推最小二乘法对隐层和输出层之间的连接权值进行构造。采用递推最小二乘法确定隐层和输出层之间的权值,可以保证较快的收敛速度^[14]。混合递阶遗传算法使递阶遗传算法训练RBF神经网络的效率得到了提高,同时也保留了递阶遗传算法的优点。

混合递阶遗传算法训练RBF神经网络步骤如下:

(1)编码。

考虑到RBF神经网络参数及其解的寻优能力,参数基因采用实数编码,每个基因用一个实数代表。控制基因仍然采用二进制编码,每个二进制位对应一个隐层节点的中心编码和宽度编码。

(2)生成初始化种群。

(3)个体解码,构造RBF神经网络隐层。

(4)递推最小二乘法确定权值。

每次迭代由输入训练样本形成的协方差矩阵递推求得权值的精确解。定义误差目标函数为:

$$E(n) = \frac{1}{2} \sum_{k=1}^n \lambda^{n-k} \sum_{i=1}^M (d_i - y_i)^2 \quad (4)$$

式中 λ 为遗忘因子, y_i 、 d_i 分别表示实际输出和期望输出。由参考文献[15]得到训练RBF神经网络连接权值的递推最小二乘法。

(5)评价RBF神经网络性能,计算出种群中个体的适应值。

考虑到训练RBF神经网络的目标是使其能在满足一定精度的要求下具有最简单的网络结构,也就是要使逼近误差精度和神经网络复杂度在综合指标达到最小。这其中逼近误差精度目标函数由误差平方和 $SSE = \sum_{i=1}^N (d_i - y_i)^2$ 来表示,网络复杂度由隐层节点个数来表示。本文采用的适应值函数为:

$$f = \frac{2N}{\left(a + be^{\frac{M}{dn}}\right) \sum_{i=1}^N (d_i - y_i)^2} \quad (5)$$

式中, N 为样本数量, M 为隐层节点个数, n 为神经网络输入节点个数, y_i 是第 i 个输入样本对应的网络的输

出, d_i 为期望输出, a 、 b 和 d 为常数。

(6)判定终止条件。如果满足条件则终止,否则继续下一步。

(7)根据个体适应值选择个体作为父代。

本文采用基于适应值比例的选择操作,个体 i 被选择的概率 $P_i = f_i / \sum f_j$,其中 f_i 为个体 i 的适应值, $\sum f_j$ 为种群个体适应值的总和。

(8)父代进行交叉、变异,产生新个体,父代和新个体形成新的种群。

(9)转步骤(3)继续执行。

4 仿真实验

在Proxy Node服务器上采集的1 000组数据,其中性能指标 P 下的参数数据作为训练样本对图3中左上角的RBFNN1进行训练。在训练网络前,先对样本中每类参数数据进行归一化处理。归一化公式采用 $y = (x - MinValue) / (MaxValue - MinValue)$,其中 $MinValue$ 和 $MaxValue$ 分别为样本中这类参数数据的最小值和最大值。根据文献[16]设置HHGA训练的RBF神经网络参数。同理训练出RBFNN2。最后,RBFNN1和RBFNN2预测值作为RBFNN3的输入,Proxy Node负载预测由RBFNN3得到。

图4和图5分别为指标 P 和指标 T 的预测结果比较,其中将混合递阶遗传优化的RBF预测结果与AHP评估值和BP预测相比较。结果得知,采用RBF的预测值与AHP评估值的平均相对误差都要小于0.01,且相对BP的预测结果明显要好。图6为总指标 S 的预测结果比较,也就是Proxy Node负载情况的预测比较。最终的Proxy Node负载预测,采用混合递阶遗传优化的RBF预测结果同样与AHP评估值的平均相对误差小于0.01,且同样优于BP预测结果。

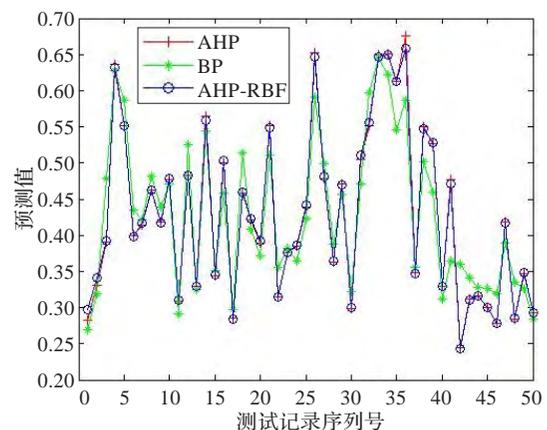


图4 指标 P 预测

5 结束语

在Swift云存储中Proxy Node的负载因素的研究上,利用AHP对Proxy Node做分析评估,采用群决策保

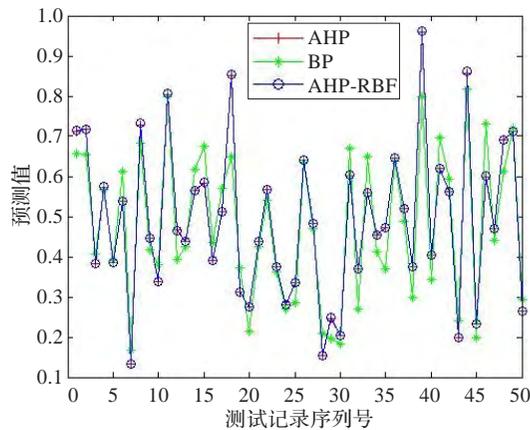


图5 指标T的预测

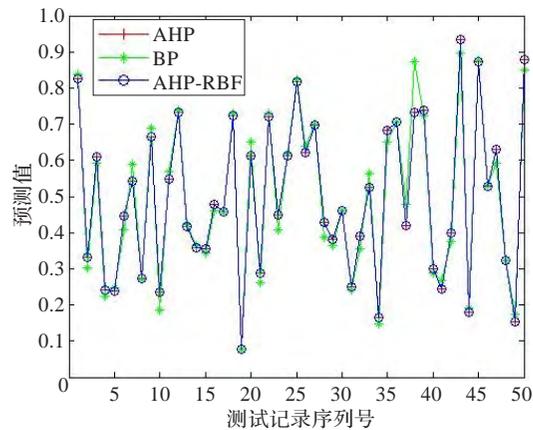


图6 总指标S的预测

证AHP评估的相对客观性,并结合混合递阶遗传训练的RBF神经网络做预测。实验结果可以得出该预测的结果相对BP预测结果要好,且预测值与AHP评估值很接近,能有效预测Proxy Node的负载,这样就可以为动态负载均衡算法提供分发客户端请求的策略提供依据。譬如,可以定时评估Swift云存储中的Proxy Node负载情况,将客户端请求分发给负载预测值与其服务队列中数量之和最小的Proxy Node。

下一步的工作,将会把对Proxy Node的负载预测用于动态负载均衡算法中,并在实际应用中与一些经典的动态负载均衡算法作比较,验证其动态负载均衡算法的性能。

参考文献:

- [1] Pepple K. Deploying OpenStack[M]. Sebastopol: O'Reilly Media, 2011.
- [2] 李庆华,郭志鑫.一种面向工作站网络的系统负载预测方法[J].华中科技大学学报:自然科学版,2002,30(6).
- [3] 许建峰,朱晴波,胡宁,等.分布式实时系统中的预测调度算法[J].软件学报,2000,11(1).
- [4] 刘万里,刘三阳.AHP中群决策判断矩阵的构造[J].系统工程与电子技术,2005,27(11).
- [5] Rumelhart D E, Hinton G E, Williams R J. Learning representations by back-propagation error[J]. Nature, 1986, 323(9):533-536.
- [6] Moody J, Darken C. Learning with localized receptive fields[M]. [S.l.]: Morgan Kaufmann Publishers, 1988.
- [7] Moody J, Darken C. Fast learning in networks of locally-tuned processing units[J]. Neural Computation, 1989(1): 281-294.
- [8] Holland J H. Adaptation in natural and artificial systems[M]. Ann Arbor: University of Michigan Press, 1975.
- [9] De Jong K A. The analysis of the behavior of a class of genetic adaptive systems[D]. Ann Arbor: University of Michigan, 1975.
- [10] Goldberg D E. Genetic algorithms in search, optimization and machine learning[M]. Boston: Addison-Wesley Longman Press, 1989.
- [11] Whitehead B A. Genetic evolution of radial basis function coverage using orthogonal niches[J]. IEEE Trans on Neural Networks, 1996, 7(6): 869-880.
- [12] Man K F, Tang K S, Kwong S, et al. Genetic algorithms for control and signal processing[M]. London: Springer-Verlag, 1997.
- [13] 石红瑞,刘勇,刘宝坤,等.基于混合递阶遗传算法的径向基神经网络学习算法及其应用[J].控制理论与应用, 2002, 19(4): 627-630.
- [14] Roy A, Govil S, Miranda R. A neural network learning theory and a polynomial time RBF algorithm[J]. IEEE Trans on Neural Network, 1997, 8(6): 1301-1313.
- [15] 王耀南.智能控制系统[M].长沙:湖南大学出版社,2004.
- [16] 郑丕谔,马艳华. RBF神经网络的递阶遗传训练新方法[J].控制与决策, 2000, 15(2): 165-168.