

文章编号: 1001-0920(2005)05-0500-05

基于模拟退火的并行粒子群优化研究

王华秋^{1,2}, 曹长修¹

(1. 重庆大学 自动化学院, 重庆 400044; 2 重庆工学院 计算机学院, 重庆 400050)

摘要: 针对粒子群优化(PSO)容易陷入局部极小, 提出将模拟退火(SA)引入并行PSO算法。这种模拟退火并行粒子群算法, 结合了并行粒子群算法的快速寻优能力和SA的概率突跳特性, 保持了群体多样性, 从而避免了种群退化。针对转炉提钒过程是一个复杂非线性反应过程而难以建立终点控制模型的问题, 提出了基于模拟退火的并行粒子群RBF网络的辨识模型, 优化了RBF核中心个数, 从而克服了随机性选择。将该模型用于预测提钒吹氧时间, 仿真结果表明预测误差不超过真实值的20%。

关键词: 并行粒子群优化; 模拟退火; 径向基网络; 转炉提钒

中图分类号: TP18 **文献标识码:** A

Parallel particle swarm optimization based on simulated annealing

WANG Hua-qiu^{1,2}, CAO Chang-xiu¹

(1. Automation Institute Chongqing University, Chongqing 400044, China; 2. Computer Department of Chongqing Institute Technology, Chongqing 400050, China. Correspondent: WANG Hua-qiu, E-mail: wanghuaqiu@cqit.edu.cn)

Abstract: To improve performance of original particle swarm optimization (PSO) algorithm and avoid trapping to local minima, the parallel PSO based on simulated annealing (SA) is proposed. The proposed algorithm combines the fast search optimum ability of parallel PSO with probability jump property of SA. It can maintain the individual diversity and restrain the degenerate phenomenon. Converter vanadium recover is a complicated nonlinear reaction, which is difficult to build up end-point control model. An identification model of RBF neural network, based on SA and parallel PSO, is presented, which is used to optimize RBF kernel number to resolve the problem of random selection. The model is applied to the prediction of oxygen blast time and simulation indicate the error of prediction do not surpass twenty percent of true value.

Key words: parallel particle swarm optimization; simulated annealing; RBF NN; converter vanadium recover

1 引言

粒子群优化算法(PSO)是由Eberhart博士和Kennedy博士于1995年提出的一种进化计算领域中的新的分支。粒子群在追逐最优粒子过程中, 随着它接近最优粒子, 其速度越来越小, 因此粒子群表现出强烈的“趋同性”, 容易陷入局部极小点^[1]。为此, 人们提出了一些PSO算法的改进算法, 如Shi等提

出的惯性权重的改进调整^[2]和模糊自适应PSO算法^[3], 吕振肃等提出的自适应变异PSO算法^[4], Fan等提出的协同计算PSO算法^[5]等。

Kirkpatrick于1983年首先提出模拟退火(SA)算法, 其最主要特征是具有跳出局部极值点区域的能力, 能寻找到全局最优或近似最优, 而与初始点的选择无关。模拟退火算法由于其固有的密集计算特

收稿日期: 2004-07-19; 修回日期: 2004-10-26

基金项目: 国家教育部博士点基金项目(98061117); 重庆市教委基础研究项目(020612); 重庆市科委攻关项目(20020828)。

作者简介: 王华秋(1975—), 男, 重庆人, 讲师, 博士生, 从事数据挖掘、并行计算的研究; 曹长修(1937—), 男, 山东蓬莱人, 教授, 博士生导师, 从事数据库、智能系统等研究。

性,存在的主要问题是运行时间长和计算内存大,这是大数据库求解的主要瓶颈。模拟退火算法的并行实现技术能较大幅度地提高其性能,能够从本质上减少计算时间。现在,人们已提出了针对模拟退火算法的并行策略,如 Onbasoglu 等提出 5 种并行 SA 在高维空间全局寻优^[6], Miki 利用 GA 优化并行 SA 的临界范围^[7]。

本文提出模拟退火并行 PSO,粒子群的追踪过程在各个相对独立的并行进程内完成,从而保证各个种群的多样性,而且在各个进程引入了模拟退火跳出粒子群局部极值。

PSO 已广泛应用于函数优化、神经网络训练、模式分类和模糊系统控制等领域。文献[1]给出了 PSO 算法综述。本文将基于 SA 的并行 PSO 用于 RBF 中心个数的优化,建立了预测吹氧时间并行转炉提钒模型。实验表明,提钒命中率得到提高。

2 基于模拟退火的并行粒子群算法

粒子通过跟踪两个“极值”来更新自己,算法结构简单,运行速度快。但是,基本粒子群优化算法在解空间内搜索时,有时会出现粒子在最优解附近“振荡”的现象,调整学习因子和惯性因子也无法完全避免,而且这个最优解可能就是局部最优。为此,本文将 PSO 算法并行化,在各个相对独立的并行进程内完成粒子群的追踪过程,根据粒子群的心理假设设计不同的学习因子 c_{11} , c_{12} 和惯性因子 ω 。有的进程粒子群对自己的运动自信,那么它的惯性因子 ω 就偏大;有的进程粒子对本身的运动认知性较强,那么个体学习因子 c_{11} 就偏大;有的进程的社会性较强,能积极交换信息和协作学习,那么它的社会学习因子 c_{12} 就偏大;或者是这几种情况的组合。这样,按照粒子不同的心理,分配不同的参数到各个进程,能够保证种群的多样性,不易陷入局部极小。用 $x_{ij} = (x_{ij1}, \dots, x_{ijk})$ 代表第 i 个进程第 j 次优化时的 k 个粒子群,则

$$\begin{aligned} v_{i(j+1)} &= \omega v_{ij} + c_{11} \text{rand}() (p_{ij} \text{Best} - x_{ij}) + c_{12} \text{rand}() (g_{ij} \text{best} - x_{ij}), \\ x_{i(j+1)} &= x_{ij} + v_{i(j+1)}. \end{aligned} \quad (1)$$

如果因粒子群更新后适应值增大而成为下一代粒子群,则会造成粒子群在计算一段时间后,群体逐渐失去迁移性而停止进化,其结果是使两代之间很相似。然而这种“过分”地相似,有一定程度的局限性。对于单峰函数,能在初始时很快向最优值进展,但在最优值附近收敛较慢;而对于多峰函数,则更容易出现局部收敛。为了避免这种停滞状态,需要对部分粒子进行类似于遗传算法的“变异”操作。本文在每个并行进程中加入模拟退火机制,用来按概

率接受恶化解。这符合并行模拟退火的思想,提高了退火算法的速度。搜索空间由可行解 $x_{ij} = (x_{ij1}, \dots, x_{ijk})$ 的集合组成,能量函数就是进行优化计算的适应值函数 $f(x_{ij})$ 。

冷却温度是跳出局部极值的关键参数。冷却温度直接影响接受准则,因此本文通过自适应调整冷却温度,即

$$t_{ij} = f(p_{ij} \text{Best}) / \overline{f(x_{ij})} - 1. \quad (2)$$

在算法运行初期,由于粒子之间的差异较大,局部最大适应值和个体平均最大适应值之比一般比较大,退火温度 t 较高。加温使其粒子可自由运动,随着算法的运行,退火温度 t 自动调整,逐渐减小;随着温度的逐渐下降,粒子逐渐形成低能态品格。当算法接近收敛时,局部最大适应值和个体平均最大适应值之比逐渐减小并趋向于 1,退火温度 t 随之逐渐接近 0。这样,在全局最优解附近的温度下降速率足够慢,接受恶化解概率也逐渐减少,所以粒子群定会形成最低能量的基态。

根据退火温度,本文设计了模拟退火概率接收准则,即

$$p = \begin{cases} 1, f(x_{ij}) < f(x_{i(j+1)}); \\ \exp\left\{-\frac{f(x_{ij}) - f(x_{i(j+1)})}{t_{ij}}\right\}, \\ \exp\left\{-\frac{f(x_{ij}) - f(x_{i(j+1)})}{f(p_{ij} \text{Best})/f(x_{ij}) - 1}\right\}, \\ f(x_{ij}) > f(x_{i(j+1)}). \end{cases} \quad (3)$$

根据粒子群进化后的适应值进行概率接受,既接收优化解,也可以接受恶化解,跳出局部极小。当新粒子的适应值增大时,系统一定接受新的粒子;当新粒子适应度降低时,先由式(3)计算出模拟退火概率 p ,如果 $p > r[0, 1]$ (0 和 1 之间的随机数) 时,系统也接受新粒子,否则接收原来的粒子。随着粒子群的进化,接受恶化解的概率 p 逐渐趋向于 0,算法从局部极值区域中跳出,找到全局最优解,并保证了算法的收敛性。

基于模拟退火的并行粒子群算法在粒子群并行计算和模拟退火温度自适应调整方面有新的理解,从理论上讲,这种算法的效率有所提高。

3 利用模拟退火并行粒子群算法优化 RBF 网络

RBF 网络采用非线性方式解决模式分类问题,其核心是将非线性可分的问题转换成一个线性可分问题。因此,隐含层的径向基激活函数的各个参数对于数据降维和模式分类至关重要。这些参数取值大都与径向基函数数目即中心个数有关,因为只有存在径向基函数个数,进行聚类中心的学习,才能决定

类与类之间的距离和径向基函数的宽度, 最终得到径向基函数矩阵. 通常径向基函数数目是凭经验决定取何值, 而径向基函数个数的选择对网络的逼近能力和效果有很大影响. 如果中心个数过少, 则不能完成分类任务; 如果中心个数过多, 则会产生过学习, 使得输入数据与训练样本之间有很小的畸变, 得不到正确的泛化结果, 而且网络规模过大也不利于工程应用^[8].

针对RBF网络中心个数选择问题, 利用模拟退火并行粒子群算法所具有的全局快速寻优的特点, 弥补中心个数的随机性, 以确定最佳数目. 训练数据存储在计算机 $P_i (i = 1, 2, \dots, m)$ 的数据 D_i , 训练目的是优化RBF网络结构. 本文的优化RBF算法的思路如下:

1) 初始化粒子群参数 ω, c_{11}, c_{12} 和模拟退火温度 t_{ij} . 初始化粒子群: 由于采用并行计算, 每个进程都分配一群粒子, 第 j 次优化粒子群的结构为

$$X_j = (x_{1j}, x_{2j}, \dots, x_{pj})^T.$$

其中: p 为进程数; j 为优化次数; $x_{ij} = (x_{ij1}, \dots, x_{ijk})$, 代表第 i 个进程第 j 次优化时的 k 个粒子, x_{ijk} 代表第 i 进程第 j 次优化的第 k 个粒子代表的径向基函数个数, 即中心数

2) RBF网络计算. 输入 N 个训练数据

$$((z_1, y_1) \quad (z_2, y_2) \quad \dots \quad (z_N, y_N)).$$

根据 x_{ijk} (中心数) 进行 K -均值聚类, 得到聚类中心; 然后计算径向基函数矩阵

$$G = (G_{ij1} \quad G_{ij2} \quad \dots \quad G_{ijk});$$

最后根据径向基函数矩阵得到权值

$$w_{ijk} = G_{ijk}^+ y = (G_{ijk}^T G_{ijk})^{-1} G_{ijk}^T y.$$

3) 评价网络结构. 输入测试数据

$$((z_1, y_1) \quad (z_2, y_2) \quad \dots \quad (z_{40}, y_{40})).$$

根据聚类中心和权值计算粒子群适应值

$$f_{ij} = (f_{ij1} \quad f_{ij2} \quad \dots \quad f_{ij40}),$$

其中 $f_{ij1} = \sqrt{\sum_{k=1}^{40} (y(k) - \hat{y}_{ij1}(k))^2 / 40}$.

4) 各个进程的局部粒子群优选

$$p_{ij}Best = (\max\{f_{ij1} \quad f_{ij2} \quad \dots \quad f_{ij40}\})^{-1},$$

并汇集到主进程; 然后主进程全局粒子群优选

$$g_jBest = \left[\max \begin{Bmatrix} f_{1j1} & f_{1j2} & \dots & f_{1j40} \\ \vdots & \vdots & & \vdots \\ f_{ij1} & f_{ij2} & \dots & f_{ij40} \end{Bmatrix} \right]^{-1},$$

其中 $(\cdot)^{-1}$ 表示由适应值反向找到对应的中心数. 主进程最后判断训练次数是否达到最大值或适应值达到要求, 并决定是否进入第5)步.

5) 利用式(2)确定退火温度, 更新全局最优粒子; 利用式(1)更新粒子的速度和位置; 利用式(3)对新粒子群进行模拟退火, 最后转第2)步.

由上述分析, 设计得到优化RBF算法流程图如图1所示.

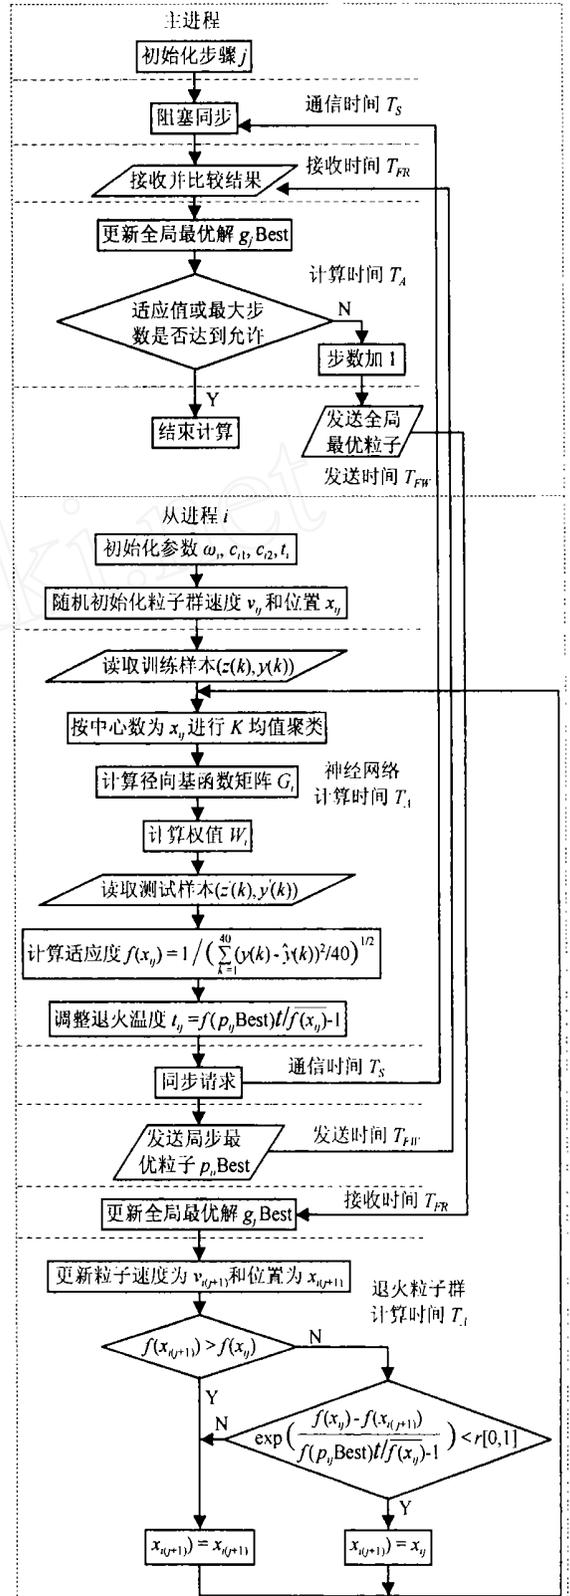


图1 优化RBF程序流程图

4 计算复杂度分析

为了分析算法的计算复杂度和收敛性, 本文通过分析并行算法的每一步找到并行进程所需的计算时间 因为MPI的发送和接收就是文件的读写, 所以文件 I/O 读写时间已被考虑在内 设: n 为粒子群数, d 为粒子群维度, P 为节点数, T_{FW} 为发送文件时间, T_{FR} 为读取文件时间, T_A 为算法计算操作时间, δ 为算法循环数, 主进程的计算时间忽略不计.

基于 Master-Slaver 结构的模拟退火并行粒子群算法计算时间可描述如下: 主进程所用时间为 $(P - 1)[T_{FR} + T_{FW} + T_S]$, 从进程所用时间为 $2T_{FR} + T_{FW} + T_S + ndT_A/P$, 则总时间为 $(ndT_A/P + PT_{FW} + (P + 1)T_{FR} + PT_S)\delta$

只要合理地将训练和测试数据集分配到各个进程, 使得每个进程的负载大致平衡, 阻塞同步时间 T_S 就小, 就可以减小同步通信量和读写时间 这时 $ndT_A/P \gg PT_{FW} + (P + 1)T_{FR}$, 总时间近似于 ndT_A/P , 只有串行计算的 $1/P$.

5 计算机仿真实验

5.1 建立实验环境

用 1~7 台联想奔月 2000 1G 作为 Slaver, 1 台 DELL Server 作为 Master, 整个网络采用以太网交换机连接, 计算机间除采用网络联接外, 其他全部独立 编程语言采用 Visual C++ 6.0 消息传递库为标准 MPI, 版本为 mpich2 MPI 是一个基于消息传递的库, 并不是一种语言, 它定义了命名方法、调用顺序和能被 Fortran 或 C/C++ 程序调用的库函数 例如: MPI_Send 和 MPI_Recv 是 MPI 点对点通信的基本库函数, MPI_Bcast 和 MPI_Reduce 是 MPI 组通信库函数

设计主从模式的 MPI 程序, 算法采用先局部后全局的思想, 其计算过程特征描述如下:

Step 1: 数据划分 Master 主进程采用随机抽样的方法向 Slaver 从进程广播数据, 为每个 Slaver 从进程划分数据

Step 2: 任意从进程 i 第 j 次在本地数据上各自独立地利用模拟退火和粒子群算法优化计算 RBF 网络得到 $p_{ij}Best$, 即局部最佳中心数

Step 3: 从进程用 MPI_Send 或 MPI_Bcast 与主进程交换计算所得到的局部最优解 $p_{ij}Best$, 使得主进程都拥有每个从进程的 $p_{ij}Best$

Step 4: Master 主进程收集来自 Slaver 从进程的 $p_{ij}Best$, 并检查是否达到最优适应度, 若达到则得到全局最优解 $gBest$, 停止搜索; 否则继续, 直到最大次数

5.2 评价并行算法性能

并行加速比

$$S = \frac{P}{1 + (T_{FR} + T_{FW})/T_A};$$

并行效率 $E = S/P$.

将结点数由 2 增加到 8, 运行基于模拟退火并行粒子群的 RBF 算法, 并记录其性能 如表 1 所示, 随着节点的增多, 该并行算法加速比增加, 总的执行时间降低, 但效率下降 算法具备一定的可伸缩性, 还可在数据通信的方式上作改进, 以提高计算效率

表 1 并行算法性能分析

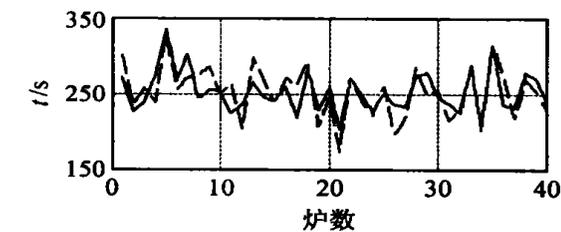
	$P=2$	$P=4$	$P=6$	$P=8$
Comm.	2 690 0	5 760 0	8 410 0	11 800 0
Comp	63 920 0	42 120 0	30 160 0	22 940 0
Total Time	66 610 0	47 880 0	38 570 0	34 740 0
Speedup	1.919 2	3.518 8	4.691 7	5.282 7
Efficiency	0.959 6	0.879 7	0.782 0	0.660 3

6 优化 RBF 网络在转炉提钒中的作用

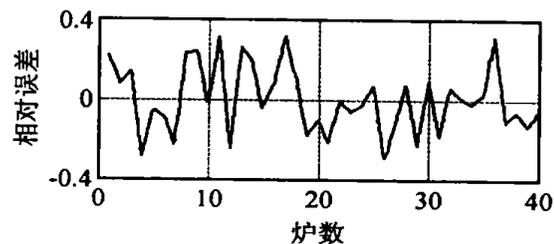
考虑到影响转炉提钒的几个因素之间存在严重的非线性关系, 为了克服以往方法实用性较差的缺陷, 采用 RBF 网络构建提钒非线性模型 由于影响转炉提钒的因素较多, 需要对转炉提钒过程的一些变化不大、且易于实现的因素进行量化和固化, 忽略一些影响较小的因素 因为铁水中的 Si, Mn, Ti 和 P 等元素含量少, 提钒过程中主要耗氧元素是 C 和 V, 因此确定模型的输入为铁水温度 T , 铁水碳 C, 铁水钒 V; 输出为吹氧时间 Y .

首先建立训练和测试数据集, 考虑到冷却剂的种类对提钒效果的影响, 选择某大型钢铁公司在 2003 年 1 月~2003 年 6 月的数据建立模型训练数据集, 这期间使用的是复合球团冷却剂, 选择铁水温度 T 在 1 207~1 314, 铁水碳 C 在 3.8%~4.9%, 铁水钒 V 在 0.222%~0.366%, 铁水硅 Si 在 0.06%~0.28% 的数据 为了获得高加速比, 最终获得 8 300 多条样本, 将其分配到 8 个结点上, 用极差标准化方法将它们转化为无量纲 0 与 1 之间的数据, 用其中 8 260 条作为训练集, 其余 40 条作为测试集 为便于比较, 40 组数据分别采用优化 RBF 网络和传统 RBF 网络同时计算; 然后在每个时刻比较分析值与模型输出值之差 两种算法的输出与实际值对比如图 2 和图 3 所示, 其中: 虚线为预测输出的吹氧时间, 实线为实际吹氧时间

从上述测试结果可以得出, 采用优化 RBF 算法训练、搜索网络最优化聚类, 能得到合理的网络结构和网络输出 平均相对误差在 20% 以内, 即命中率在 80% 以上

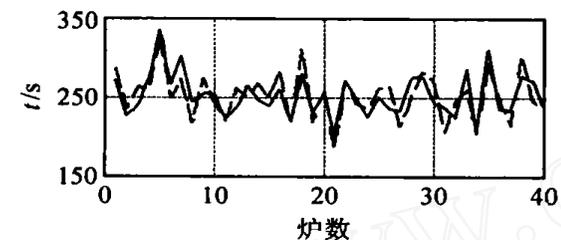


(a) 预测吹氧时间

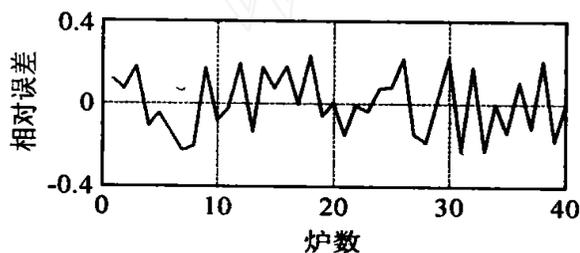


(b) 预测值相对误差

图2 RBF模型吹氧时间输出及误差



(a) 预测吹氧时间



(b) 预测值相对误差

图3 优化RBF模型吹氧时间输出及误差

7 结论

本文提出了一种基于模拟退火的并行粒子群优化算法。该算法针对PSO算法可能出现的停滞现象,引入了基于模拟退火机制和并行计算方法。理论

和实践证明,模拟退火并行粒子群RBF算法可以对提钒过程进行及时识别和控制,对钢铁提钒处理生产过程具有指导作用。应当指出,在粒子群参数选择、退火温度确定、并行任务分解这几方面的处理还有不完善之处,尚需改进,以提高网络得到全局最优解的概率。

参考文献(References)

- [1] 谢晓锋, 张文俊, 杨之廉. 微粒群算法综述[J]. *控制与决策*, 2003, 18(2): 129-134
(Xie X F, Zhang W J, Yang Z L. Overview of particle swarm optimization[J]. *Control and Decision*, 2003, 18(2): 129-134.)
- [2] Shi Y, Eberhart R. A modified particle swarm optimizer[A]. *Proc IEEE Int'l Conf on Evolutionary Computation* [C]. Anchorage: IEEE Press, 1998: 69-73.
- [3] Shi Y, Eberhart R. Fuzzy adaptive particle swarm optimization [A]. *IEEE World Congress on Evolutionary Computation* [C]. Seoul, 2001: 101-106.
- [4] 吕振肃, 侯志荣. 自适应变异的粒子群优化算法[J]. *电子学报*, 2004, 32(3): 416-420
(Lv Z S, Hou Z R. Particle swarm optimization with adaptive mutation [J]. *Acta Electronica Sinica*, 2004, 32(3): 416-420.)
- [5] Fan den Bergh, Engelbrecht A P. Cooperative learning in neural networks using particle swarm optimizations [J]. *South African Computer J*, 2000, 26(11): 84-90.
- [6] Onbasoglu E, Ozdamar L. Parallel simulated annealing algorithms in global optimization [J]. *J of Global Optimization*, 2001, 19(1): 27-50.
- [7] Mitsunori M K, Tomoyuki H, Toshihiko F. Parallel simulated annealing with adaptive neighborhood determined by GA [A]. *Proc IEEE Int'l Conf Syst Man Cybern* [C]. Washington: Institute of Electrical and Electronics Engineers Inc, 2003: 26-31.
- [8] Robert J S, James J C, Ahmad F A. Approximation of nonlinear systems with radial basis function neural networks[J]. *IEEE Trans Neural Networks*, 2001, 19(4): 1-14.

(上接第499页)

- [4] Huang Y L, Lou H H, Gong J P, et al. Fuzzy model predictive control[J]. *IEEE Trans on Fuzzy Systems*, 2000, 8(6): 665-678.
- [5] Abonyi J, Nagy L, Szeifert F. Fuzzy model-based predictive control by instantaneous linearization [J]. *Fuzzy Sets and Systems*, 2001, 120(1): 109-122.
- [6] Gustafson D, Kessel W. Fuzzy clustering with a fuzzy covariance matrix[A]. *Proc of IEEE Conf on Decision*

and Control[C]. San Diego, 1979: 761-766.

- [7] Fischer M, Nelles O, Isemann R. Predictive control based on local linear fuzzy models[J]. *Int J System Science*, 1998, 29(7): 797-815.
- [8] Roubos J A, Molloy S, Babuka R, et al. Fuzzy model-based predictive control using Takagi-Sugeno models [J]. *Int J Approximate Reasoning*, 1999, 22(1-2): 3-30.