

文章编号: 1001-0920(2012)07-1027-05

## 基于动态邻域微粒群的 Smith 预估双控制器设计

范剑超, 韩敏

(大连理工大学 电子信息与电气工程学部, 辽宁 大连 116023)

**摘要:** 针对模型未知时滞系统的预测补偿控制, 提出一种基于动态邻域拓扑微粒群算法以优化动态神经网络的参数, 并将其作为预估器和辨识器应用于一种新的 Smith 预估双控制器结构设计. 利用微粒群算法空间搜索能力指标, 动态建立邻域拓扑结构, 优化神经网络参数, 并将两者的组合模型应用于新的双控制器结构, 将负载扰动和定值控制分开, 以提高 Smith 预测补偿模型的控制精度和鲁棒性, 最后通过仿真验证了所提出方法的有效性.

**关键词:** 时滞系统; Smith 预估; 动态邻域; 微粒群优化

**中图分类号:** TP273

**文献标识码:** A

## Smith predictive double controllers design based on dynamic neighbor particle swarm optimization algorithm

FAN Jian-chao, HAN Min

(Faculty of Electronic Information and Electrical Engineering, Dalian University of Technology, Dalian 116023, China.  
Correspondent: HAN Min, E-mail: minhan@dlut.edu.cn)

**Abstract:** For the unknown time-delay system of predictive compensation control, a dynamic neighborhood topology particle swarm optimization(PSO) algorithm is presented to optimize the parameters of dynamic neural networks, which is taken as a predictor and identifier in the new double-controller Smith predict structure, respectively. By using the particle swarm optimization space search capability index, the neighborhood topologies of PSO algorithm are dynamically created to optimize the neural network parameters. After that, the combination model is applied to the new two double-controller structure, which separates the load disturbance and fixed value control, and improves the control precision and robustness of Smith predictive compensation model. Finally, simulation results show the effectiveness of the proposed method.

**Key words:** delay system; Smith predictor; dynamic topology; particle swarm optimization

### 1 引言

在滞后系统的控制方法设计中, 将被控对象的延迟时间作为滞后系统的关键参数一直是预测控制系统设计中不可缺少的重要因素<sup>[1]</sup>. 包含纯滞后的控制系统通常存在较大的超调量和较长的调整时间, 当受到外界干扰时, 控制器无法立刻产生抑制作用<sup>[2-3]</sup>. 所以, 任正云等<sup>[4]</sup>提出将双预测 PI 控制用于纯滞后系统控制; 李迅等<sup>[5]</sup>将模型参考自适应模型与 Smith 预估器相结合来克服扰动作用; Chen 等<sup>[6]</sup>将灰度预估引入 Smith 控制, 从而抑制线性延迟系统中的周期性扰动. Tian<sup>[7]</sup>提出将多控制器结构用于预测控制, Kaya<sup>[8]</sup>把内膜控制和 Smith 相结合, 利用典型非线性环节调整时间延迟参数. 然而, 在实际工业过程中被控对象大多具有复杂、不确定性等特性, 基于被

控对象精确数学模型的 Smith 预估控制很难得到有效地应用, 并且对于包含不确定时滞的工业过程, 无法建立内膜算法中的非参数模型. 因此, 问题的关键是建立精确的预估模型, 辨识出滞后系统的延迟时间参数. 前馈神经网络 (FNN) 模型结构简单, 具有能以任意精度逼近非线性对象的特点, 已经被 Narendra<sup>[9]</sup>等众多学者应用于非线性系统的辨识和控制领域, 并取得了良好的效果. Balestrino 等<sup>[10]</sup>利用 FNN 辨识延迟时间参数, 但会受到网络参数和辨识对象的限制. Ren 等<sup>[11]</sup>扩展了自由延迟神经网络, 以估计滞后系统的延迟时间参数. 然而, 基于误差反馈学习的 FNN 仅是一种静态映射, 学习速度较慢.

本文提出一种邻域拓扑微粒群算法 (NTPSO), 用于包含自适应延迟参数的动态前向神经网络

收稿日期: 2010-12-30; 修回日期: 2011-03-14.

基金项目: 国家自然科学基金项目(61074096); 国家863计划项目(2007AA04Z158).

作者简介: 范剑超(1985—), 男, 博士生, 从事优化计算、预测控制等研究; 韩敏(1959—), 女, 教授, 博士生导师, 从事神经网络、混沌序列分析等研究.

(DFNN)<sup>[12]</sup>的学习. 该算法能够根据 PSO 粒子搜索空间, 自适应地确定微粒之间的邻域拓扑关系, 避免一般 PSO 算法存在的提前收敛问题, 同时使神经网络快速收敛, 减少由人工参数设定所带来的影响. 在 DFNN+NTPSO 模型基础上, 设计了 Smith 预估双控制器结构. 该控制器采用神经网络结构, 并将 DFNN+NTPSO 作为辨识器和预估器来精确估计被控对象的延迟时间参数; 采用双闭环控制结构分离定值控制和扰动控制, 增强了系统的鲁棒性.

## 2 邻域拓扑微粒群算法

标准微粒群算法对于第  $t$  代的第  $i$  个微粒, 其第  $d$  维 ( $1 \leq d \leq D$ ) 的速度更新公式<sup>[13]</sup>如下:

$$\begin{cases} v_{id}(t+1) = wv_{id}(t) + c_1 \text{rand}_1() (p_{id}(t) - \\ \quad x_{id}(t)) + c_2 \text{rand}_2() (p_{gd}(t) - x_{id}(t)), \\ x_{id}(t+1) = x_{id}(t) + v_{id}(t+1). \end{cases} \quad (1)$$

其中:  $w \in [0, 1]$ ;  $\text{rand}_1(), \text{rand}_2() \in [0, 1]$ ;  $c_1, c_2$  为非负常数;  $\bar{x}_i = (x_{i1}, x_{i2}, \dots, x_{iD})$  为微粒的当前位置,  $\bar{v}_i = (v_{i1}, v_{i2}, \dots, v_{iD})$  为微粒的速度. 第  $i$  个微粒经历过的最好位置  $P_{\text{best}}$ :  $\bar{p}_i = (p_{i1}, p_{i2}, \dots, p_{iD})$ , 所有微粒最好位置  $P_{g\text{best}}$ :  $\bar{p}_g = (p_{g1}, p_{g2}, \dots, p_{gD})$ .

为了克服微粒群算法微粒过早收敛的问题, 引入随机邻域拓扑方法建立邻域拓扑, 如下所示:

$$N_i(t) = \{j, j \neq i \mid \varepsilon_{ij} \leq \varepsilon\}. \quad (2)$$

当产生的随机数  $\varepsilon_{ij} < \varepsilon$  时, 两个微粒之间建立连接. 在建立的邻域关系中寻找当前该拓扑关系中的最优微粒位置, 所以速度进化公式修正为

$$v_{id}(t+1) = wv_{id}(t) + c_1 \text{rand}_1() (p_{id}(t) - x_{id}(t)) + c_2 \text{rand}_2() (l_{gd}(t) - x_{id}(t)), \quad (3)$$

其中  $l_{gd}(t)$  为该微粒在当前时刻邻域微粒的最优位置. 令  $\bar{p}_g = \max(l_{g1}, l_{g2}, \dots, l_{gM})$ ,  $M$  是建立邻域的总数. 在这种基于邻域关系的微粒群寻优算法中, 邻域关系多是固定的, 且模式化的, 这样不利于各拓扑关系之间微粒的信息交流. 本文根据邻域微粒搜索空间, 自动建立新的邻域拓扑关系, 使不同群体间的信息可以共享, 寻找新的拓扑邻域中的最优点, 保证 PSO 算法在后期具有足够的寻优能力. 分析微粒群算法中邻域最优点和微粒当前位置的关系, 建立算法搜索空间的公式<sup>[14]</sup>如下:

$$R_1 = \max(l_{jd}(t), x_{id}(t)) - \min(l_{jd}(t), x_{id}(t)). \quad (4)$$

因此, 可以进一步得到邻域多样性的定义.

**定义 1** 邻域的多样性, 即整个微粒群算法的潜在搜索空间, 定义为

$$\text{diversity}(S) = \frac{1}{S * L} \sum_{i=1}^S |R_1|. \quad (5)$$

其中:  $S$  为邻域内的微粒个数,  $L$  为邻域连接的长度. 可以发现, 多样性指标在算法运行中随种群内个体分布的改变而变化: 进化的早期, 分散于解空间的个体在进化操作下迅速向可能最优的区域集中, 种群多样性急剧减小; 进化中期, 个体从一些局部极小点向另一些极值点迁移, 并在此过程中发现全局最小区域, 多样性急剧减小; 最后, 优胜子群体将集中于最有可能发现全局最优的区域附近进行搜索, 多样性指标在小范围内变化. 当  $\text{diversity}(S) < d_{\min}$  时, 根据式 (2) 建立新的邻域拓扑结构, 重新返回进化中期, 这样便保证了算法的后期持续进化能力.

## 3 Smith 预估双控制器结构设计

所采用的动态前馈神经网络<sup>[12]</sup>分别在输入层与隐含层, 隐含层与输出层之间加入自适应延迟参数, 第 1 部分延迟参数主要提高网络的动态特性, 第 2 部分则辨识系统中的纯滞后时间. 将神经网络全部参数作为 NTPSO 的维数, 进行迭代寻优, 每次的群体最优值即为当前最优网络参数. 然后, 基于 DFNN+NTPSO 在结构上的特性, 将其作为预测器和辨识器, 设计 Smith 双控制器结构. DFNN 模型作为预测器只需要将所有输出层延迟参数去除, 即可消除被辨识对象中的纯滞后时间, 得到系统的预测模型. 在控制结构上, 提出带有模型误差补偿的基于邻域拓扑微粒群优化的动态神经网络预估模型的双控制器结构, 分离定值控制与扰动控制, 避免闭环控制系统设计中控制性和鲁棒性的冲突.

### 3.1 Smith 预估双控制器系统结构

基于 DFNN+NTPSO 的预测控制结构如图 1 所示. 整个控制系统分为两个闭环结构: 控制器  $G_{C1}$  和预测模型  $\hat{G}_m$  构成第 1 个闭环,  $\hat{y}_P(t)$  作为  $\hat{G}_m$  的预测输出, 与给定值  $r(t)$  做差, 获得误差  $e_1(t)$ , 通过主控制器  $G_{C1}$  得到控制量  $u_1(t)$ , 作用于预测模型  $\hat{G}_m$ , 被控对象  $G_P$  和辨识器  $G_m$ . 第 2 个闭环由被控对象  $G_P$ , 辨识器  $G_m$  和模型误差补偿控制器  $G_{C2}$  组成.




图 1 Smith 预估双控制器系统结构图

在理想情况下, 辨识模型  $G_m$  与被控对象  $G_P$  一致时,  $e_2(t) = 0$ ,  $u_2(t) = 0$ ,  $G_P$  仅受到主控制器  $G_{C1}$  的控制量  $u_1(t)$  作用, 此时系统为经典 Smith 预估控制结构. 当受到扰动作用  $f(t)$ , 或者神经网络模型存在

误差  $G_m \neq G$  时,  $G_P$  在  $G_{C1}$  的控制作用下必然与给定值  $r(t)$  存在偏差  $e_2(t) \neq 0$ . 所以引入  $G_{C2}$ , 消除建模偏差和外界扰动对控制系统的影响, 提高了控制系统的鲁棒性.

根据控制系统结构图, 可以得到系统的传递函数

$$Y(s) = H_r(s)R(s) + H_f(s)F(s). \quad (6)$$

其中:  $H_r(s)$  为定值控制的传递函数,  $H_f(s)$  为负载扰动的传递函数, 根据梅逊公式, 令其具体描述分别如下:

$$H_r(s) = \frac{G_{C1}(s)P(s)e^{-ds}}{1 + G_{C1}(s)\hat{G}_m(s)} \frac{1 + G_{C2}(s)\hat{G}_m(s)e^{-d^*s}}{1 + G_{C2}(s)P(s)e^{-ds}},$$

$$H_f(s) = \frac{G_P(s)e^{-ds}}{1 + G_{C2}(s)P(s)e^{-ds}}. \quad (7)$$

### 3.2 控制结构与性能分析

为了便于对本文提出的 Smith 预估双控制器结构进行分析, 控制采用 PI 控制器, 即

$$G_C(s) = K_C(1 + \frac{1}{T_C s}). \quad (8)$$

被控对象的模型  $G_P$  采用一阶惯性滞后环节进行模拟, 所以期望的系统辨识模型  $G_m$  分别表示为

$$G_P(s) = P(s)e^{-ds} = \frac{K_P}{T_P s + 1} e^{-ds}, \quad (9)$$

$$G_m(s) = \hat{G}_m(s)e^{-d^*s} = K_P^*(1 + \frac{1}{T_P^* s})e^{-d^*s}. \quad (10)$$

其中:  $d$  为纯滞后延迟时间,  $d^*$  为辨识后得到的系统纯滞后时间. 因此, 根据式 (7), 将式 (9) 和 (10) 代入, 可以得到  $H_r(s)$  和  $H_f(s)$  的表达形式

$$H_r = \frac{K_{C1}K_P(T_{C1}s + 1)e^{-ds}}{T_{C1}s(T_P^*s + 1) + K_{C1}K_P^*(T_{C1}s + 1)} \times \frac{T_{C2}s(T_P^*s + 1) + K_{C2}K_P^*(T_{C2}s + 1)e^{-d^*s}}{T_{C2}s(T_Ps + 1) + K_{C2}K_P(T_{C2}s + 1)e^{-ds}},$$

$$H_f = \frac{K_P T_{C2} s e^{-ds}}{T_{C2}s(T_Ps + 1) + K_{C2}K_P(T_{C2}s + 1)e^{-ds}}. \quad (11)$$

当过程模型较好时, 即  $G_P(s) = G_m(s)$ , 由式 (7) 可以得到定值控制的传递函数变化为

$$H_r(s) = \frac{G_{C1}(s)P(s)e^{-ds}}{1 + G_{C1}(s)G_P(s)},$$

它仅由定值控制器  $G_{C1}(s)$  决定, 而且发现  $H_f(s)$  仅由  $G_{C2}(s)$  决定, 因此  $G_{C2}(s)$  可以称作负载控制器.

$\lim_{s \rightarrow 0} H_r(s) = 1$ ,  $\lim_{s \rightarrow 0} H_f(s) = 0$ , 意味着系统的输出可以很好地追踪给定值, 没有稳态误差, 即便是双环无接触, 同样  $y(t)$  可以很好地跟踪  $r(t)$  的变化. 而控制信号

$$H_r(s) = \frac{G_{C1}(s)}{1 + G_{C1}(s)\hat{G}_m(s)} R(s) = \frac{K_{C1}(T_{C1}s + 1)(T_P^*s + 1)R(s)}{T_{C1}s(T_P^*s + 1) + K_{C1}K_P^*(T_{C1}s + 1)}. \quad (12)$$

同理可以得到  $\lim_{s \rightarrow 0} U_1(s) = \frac{1}{K_P} R$ . 因此总的控制信号为  $\lim_{s \rightarrow 0} U(s) = \frac{1}{K_P} R - F$ , 控制信号  $u_2(t)$  可以看作是对未知负载扰动的一种估计.

在经典 Smith 控制中, 辨识模型和预测模型的精度对控制精度有很大的影响, 所以需对模型失配的不敏感性进行理论分析, 即  $K_P^* \neq K_P$ ,  $T_P^* \neq T_P$ ,  $d^* \neq d$ . 此时, 控制信号

$$\lim_{s \rightarrow 0} U_1(s) = \frac{1}{K_P^*} R,$$

$$\lim_{s \rightarrow 0} U_2(s) = F + (\frac{1}{K_P^*} - \frac{1}{K_P}) R.$$

因此, 可以发现

$$\lim_{s \rightarrow 0} U(s) = \lim_{s \rightarrow 0} (U_1(s) - U_2(s)) = \frac{1}{K_P} R - F. \quad (13)$$

通过式 (13) 可以得到如下的结论: 在模型失配的情况下, 控制系统的总控制信号并没有发生变化, 体现出所设计控制系统的鲁棒性. 这样设计的双环无接触控制结构, 可以很清楚地理解每个控制器的控制作用,  $G_{C1}(s)$  主要是对设定值的动态响应控制,  $G_{C2}(s)$  主要是对负载扰动的控制, 而模型失配所带来的误差, 是由  $G_{C1}(s)$  和  $G_{C2}(s)$  共同作用抵消, 消除了对模型精度的依赖.

### 3.3 神经网络控制器

将第 1 个闭环部分的目标函数定义为

$$J_1(t) = \frac{1}{2} e_1^2(t). \quad (14)$$

采用梯度下降的方法设计神经网络自适应控制器  $G_{C1}$ , 选用 3 层 BP 神经网络, 误差  $e_1(t)$  作为输入, 控制量  $u_1(t)$  作为输出, 控制律为

$$u_1(t) = \sum_{i=1}^n \omega_2(t) \text{sig} \left( \sum_{j=1}^m \omega_1(t) e_1(t) \right). \quad (15)$$

其中:  $\omega_1$  和  $\omega_2$  分别是各层之间的连接权值,  $m$  和  $n$  对应各层神经元个数.

权值更新如下所示:

$$\omega(t+1) = \omega(t) - \eta_1 \frac{\partial J(t)}{\partial \omega(t)}, \quad (16)$$

$$\frac{\partial J(t)}{\partial \omega(t)} = -e_1(t) \frac{\partial y_P(t)}{\partial \omega(t)}, \quad (17)$$

其中  $\eta_1$  为参数调整学习率.

将式 (17) 代入 (16), 有

$$\omega(t+1) = \omega(t) + \eta_1 \frac{\partial y_P(t)}{\partial \omega(t)}. \quad (18)$$

同理, 模型误差补偿控制器  $G_{C2}$  的目标函数定义为

$$J_2(t) = \frac{1}{2} e_2^2(t). \quad (19)$$

依据梯度下降法得控制律为

$$u_2(t+1) = u_2(t) + \eta_2 e_2(t) \frac{\partial y(t)}{\partial u_2(t)}. \quad (20)$$

#### 4 Smith 预估双控制器仿真分析

利用如下非线性延迟模型检验所提出控制方法的有效性:

$$y(t) = \frac{u(t)}{1 + y^2(t-1)} + u^3(t-10). \quad (21)$$

由式(21)可得,被控对象具有 10 个单位的纯滞后时间,采用神经网络 PID 控制器进行控制,获得 2000 组被控对象输入输出数据作为 DFNN+NTPSO 的学习数据,如图 2 所示,仿真条件如表 1 所示.




图 2 神经网络学习数据

表 1 非线性延迟系统仿真条件

参数名称	参数值
神经网络结构	2-20-20-1
激励函数	$f(x) = A \frac{1 - e^{-x}}{1 + e^{-x}}$
幅值 A	6
迭代次数	10 000
种群规模	20
学习维数	561
搜索范围	(-15,15)
幅度幅值	$v_{\max} = 2$
动态连接邻域阈值	0.1

DFNN 中有 60 个延迟变量,两部分初始值分别设置为 1 和 12,选用前 1000 组数据训练 DFNN+NTPSO 模型,剩余数据测试组合模型的泛化能力.训练之后,辨识器  $G_m$  的输出如图 3 所示,可以看出  $G_m$  可以很好地逼近被控对象,输出层延迟参数 14 个值为 10,剩余 6 个值为 9.因此,DFNN+NTPSO 可以准确地辨识出被控对象的纯滞后时间.




图 3 DFNN+NTPSO 的系统辨识结果

为了验证 NTPSO 算法和 DFNN 网络在对滞后系统辨识中的有效性,分别将多层感知机网络 (MLP),基于遗传算法 (GA) 的多层感知机网络,基于蚁群算法 (ACO) 的多层感知机网络和基于 NTPSO 算法的多层感知机网络与本文提出的基于 NTPSO 优化的 DFNN 网络进行对比,采用相同的网络初始条件进行训练,仿真结果如表 2 所示.通过 MLP 算法和 MLP+GA 算法的对比可以看出, NTPSO 算法可以大大节省神经网络的学习时间.相对其他进化算法,由于引入动态邻域,耗费了一定的计算时间,但从测试结果可以看出, NTPSO 和 DFNN 中动态神经元的引入明显提高了神经网络的学习和泛化能力.

表 2 系统辨识结果对比

	训练误差	泛化误差	时间消耗/min
MLP	0.791 910	0.018 030	14.55
MLP+GA	0.003 773	0.069 623	31.22
MLP+ACO	0.005 361	0.010 962	4.12
MLP+PSO	0.065 247	0.004 765	4.13
MLP+NTPSO	0.004 765	0.065 247	5.35
DFNN+NTPSO	0.000 984	0.000 498	5.36

进而,将式(21)作为被控对象  $G_P$  进行控制,响应曲线如图 4 所示.其中方波矩形线为目标曲线,分别是 DFNN+NTPSO, MLP+NTPSO, MLP 作为控制结构的辨识器和预估器,而 Smith 预估控制方法是通过精确数学模型预测得到的系统输出曲线.从图中的对比可以看出,所提出的基于 DFNN+NTPSO 的 Smith 预估双控制器模型相对于其他神经网络模型,因其具有较高的精确度,控制精度较高,无超调现象.而其他两种神经网络模型都有不同的超调和振荡现象,但是由于双控制器结构,充分克服了模型精度不高带来的控制效果差的影响,仍然可以将输出跟踪输入的动态响应.因此,可以认为所提出的滞后系统辨识和控制方法为被控对象参数未知的滞后控制系统设计提供了新的途径.




图 4 控制系统输出曲线

此外,为验证所提出方法的鲁棒性,在第 250 步将被控对象表达式(21)的比例系数改为 0.85,延迟时间调整为 8,即

$$y(t) = \frac{0.85y(t)}{1 + y^2(t-1)} + u^3(t-8). \quad (22)$$

图5中给出了阶跃值为1.5的动态响应. 从图中可看出, 被控对象 $G_P$ 的输出在模型误差补偿器 $G_{C2}$ 的作用下, 仍能恢复到给定值 $r(t)$ , 所以所提出的控制模型对模型失配扰动等现象具有较好的控制效果, 而经典 Smith 方法不具有自调整的功能.




图5 模型失配时的系统响应曲线

## 5 结 论

针对模型未知的非线性滞后系统控制问题, 采用一种新型的邻域拓扑微粒群学习算法, 克服了传统神经网络算法收敛速度慢的缺陷, 可在表达包含滞后非线性系统动态特性的同时, 辨识出该系统所包含的滞后时间. 此外, 提出了基于 DFNN+NTPSO 的 Smith 预估双控制器模型, 以分离负载扰动和定值控制. 通过仿真实例, 验证了所提出模型对参数未知的大滞后系统具有较好的控制效果和较强的鲁棒性.

## 参考文献(References)

- [1] Lai C L, Hsu P L. Design the remote control system with the time-delay estimator and the adaptive smith predictor[J]. IEEE Trans on Industrial Informatics, 2010, 6(1): 73-80.
- [2] Normey-Rico J E, Camacho E F. Unified approach for robust dead-time compensator design[J]. J of Process Control, 2009, 19(1): 38-47.
- [3] Zhang W D, Rieber J M, Gu D Y. Optimal dead-time compensator design for stable and integrating processes with time delay[J]. J of Process Control, 2008, 18(5): 449-457.
- [4] 任正云, 邵惠鹤, 张立群. 一类非自衡加纯滞后系统的双预测 PI 控制[J]. 控制与决策, 2004, 19(4): 459-461. (Ren Z Y, Shao H H, Zhang L Q. Double predictive PI control for integrator plus time delay processes[J]. Control and Decision, 2004, 19(4): 459-461.)
- [5] 李迅, 宋东球, 喻寿益, 等. 基于模型参考自适应 Smith 预估器的反馈式 AGC 厚度控制系统[J]. 控制理论与应用, 2009, 26(9): 999-1003. (Li X, Song D Q, Yu S Y, et al. Feedback automatic gauge control system using model reference adaptive Smith predictor[J]. Control Theory and Application, 2009, 26(9): 999-1003.)
- [6] Chen Y D, Tung P C, Fuh C C. Modified Smith predictor scheme for periodic disturbance reduction in linear delay systems[J]. J of Process Control, 2007, 17(10): 799-804.
- [7] Tian Y C, Gao F R. Double-controller scheme for control of processes with dominant delay[C]. IEE Proc Control Theory and Applications, 1998, 145(5): 479-484.
- [8] Kaya I. IMC based automatic tuning method for PID controllers in a Smith predictor configuration[J]. Computers and Chemical Engineering, 2004, 28(3): 281-290.
- [9] Narendra K S, Parthasarathy K. Identification and control of dynamical systems using neural networks[J]. IEEE Trans on Neural Networks, 1990, 1(1): 4-27.
- [10] Balestrino A, Verona F B, Landi. On-line process estimation by ANNs and Smith controller design[C]. IEE Proceedings Control Theory And Applications, 1998, 145(2): 231-235.
- [11] Ren X M, Rad A B. Identification of nonlinear systems with unknown time delay based on time-delay neural networks [J]. IEEE Trans on Neural Network, 2007, 18(5): 1536-1541.
- [12] Han M, Fan J C, Han B. An adaptive dynamic evolution feedforward neural network on modified particle swarm optimization[C]. Proc of Int Joint Conf on Neural Networks. Atlanta, 2009: 1083-1089.
- [13] Kennedy, J, Mendes R. Neighborhood topologies in fully informed and best-of-neighborhood particle swarms [J]. IEEE Trans on Systems, Man, and Cybernetics, Part C: Applications and Reviews, 2006, 36(4): 515-519.
- [14] Liang J J, Qin A K, Suganthan P N, et al. Comprehensive learning particle swarm optimizer for global optimization of multimodal functions[J]. IEEE Trans on Evolutionary Computation, 2006, 10(3): 281-295.