



# 一种神经网络自学习控制结构与算法<sup>1)</sup>

朱 刚      周贤伟      张 凯      尤昌德      胡保生

(北方交通大学电子信息工程学院 北京 100044)  
(E-mail: gang-zh@263.net)

(西安交通大学电子信息学院 西安 710049)  
(E-mail: xwzhou@center.njtu.edu.cn)

**关键词** 神经网络, 自学习控制, 训练算法, 优化控制, 温度控制.

## RESEARCH ON THE SELF-LEARNING CONTROL BASED ON NEURAL NETWORKS

ZHU Gang ZHOU Xianwei

(School of Electronics & Information Engineering, Northern Jiaotong Univ., Beijing 100044)

ZHANG Kai YOU Changde HU Baosheng

(Electronics & Information College, Xi'an Jiaotong Univ., Xi'an 710049)

**Key words** Neural network, self-learning control, training algorithm, optimal control, temperature control.

## 1 引言

神经网络自学习控制代表性结果之一<sup>[1]</sup>是采用一个多层前馈网络(对象仿真器)辨识被控对象,采用另一个神经网络(控制器)学习控制仿真器后,再控制真实对象. 这个思想对于解决复杂工业过程对象优化控制问题具有一定意义. 但是,直接应用仍存在问题:1) 其中对象仿真器结构、对象模型结构、控制器训练结构是基于状态空间模型,要求状态变量可测. 在一般过程控制中,这个条件不是总能得到满足. 2) 未考虑控制量存在约束情况. 本文提出面向输入输出模型的仿真器网络,推出学习算法,提出控制器训练结构并推出学习算法,实现约束控制下的多目标终态控制,并将结果应用于感应加热系统,实现温度优化控制.

## 2 对象仿真器网络结构及学习算法<sup>[2]</sup>

面向输入输出模型的仿真器是由 Adaline 子网络与 BP 子网络复合而成. 其输出层  $k$

1) 北方交通大学攀登计划资助项目及校科研基金资助项目.

神经元输入为

$$net_k = \left( \sum_j W_{kj} o_j + W_{k,l+1} \right) + \left( \sum_i \gamma_{ki} o_i + \gamma_{k,m+1} \right) = net_k^N + net_k^L,$$

$$k = 1, \dots, n, i = 1, \dots, m, j = 1, \dots, l,$$

其中,  $W$  为 BP 网络权值,  $\gamma$  为 Adaline 网络权值. 对应神经元输出为(作用函数为线性函数)

$$o_k = b_k + a_k = f_k(net_k) = net_k,$$

其中  $b_k$  为 BP 子网络输出,  $a_k$  为 Adaline 子网络输出.

复合网络训练时,先训练 Adaline 子网络(线性训练),再进行复合训练,以加快训练速度.线性训练时,根据广义  $\delta$  规则得权值修正公式

$$\Delta \gamma_{ki} = \eta(t_k - a_k) o_i.$$

复合训练时,根据梯度下降推出权值修正公式为

$$\text{输出层 } \Delta W_{kj} = \eta \delta_k^N \cdot o_j, \delta_k^N = (t_k - o_k) f'_k(net_k^N); \Delta \gamma_{ki} = \eta \delta_k^L o_i, \delta_k^L = (t_k - o_k) f'_k(net_k^L);$$

$$\text{隐层 } \Delta W_{ji} = \eta \delta_j o_i, \quad \delta_j = f'_j(net_j) \sum_k \delta_k^N W_{kj}.$$

应用仿真器及其学习算法,根据串并联辨识结构,对被控对象实施正向建模后,进行控制器训练,需将多个网络串联,形成大复合网络.仿真器输入层( $i$ 层)成为隐层.其神经元前馈联结情况与一般多层前馈网络有所不同.根据梯度下降及求全导数法则,推出等效误差计算公式为

$$\delta_i = \left( \sum_j \delta_j W_{ji} + \sum_k \delta_k^L \gamma_{ki} \right) f'_i(net_i), \quad (1)$$

其中  $j$  层为前馈相邻层,  $k$  层为前馈非相邻层,  $W, \gamma$  为相应权值.当权值为 1 且作用函数为线性函数时,可得

$$\delta_i = \sum_j \delta_j + \sum_k \delta_k^L. \quad (2)$$

### 3 控制器网络、训练结构及算法

控制器网络为多层前馈网络.其输出层神经元作用函数为线性函数.

考虑被控对象

$$y_p = F[y_p(k-1), \dots, y_p(k-n), u(k-1), \dots, u(k-m)],$$

在输出反馈控制

$$u(k) = g[y_p(k)]$$

作用下的终态控制问题.优化控制律  $g(\cdot)$  一般为非线性映射.若采用神经网络(控制器)实现,并用仿真器再现被控对象动态特性,则  $y(0)$  演化到  $y(T+1)$  过程,可以用控制器与仿真器串联结构体现,如图 1 所示.其中  $E_h, C_h (0 \leq h \leq T)$  分别为对应时间的仿真器与控制器.这样,综合优化控制律问题就转化为控制器训练问题.

根据图 1,  $C_h (0 \leq h \leq T), E_h (0 \leq h < T)$  网络输出层成为大网络的隐层,可以通过误差反传得到等效输出误差.其神经元作用函数为线性函数,并且与前馈神经元直接相联.根据式(2)及指标函数  $J = \frac{1}{2} (y_d - y_{T+1})^2$ ,推出等效误差计算公式如下:

$$\delta_T^E(y_{T+1}) = y_d - y_{T+1}; \quad (3)$$

$$\delta_{T-h}^C(u_{T-h}) = \begin{cases} \sum_{i=0}^h \delta_{T-i}^E(u_{T-h}), & 0 \leq h \leq m, \\ \sum_{i=0}^h \delta_{T-h+i}^E(u_{T-h}), & m < h \leq T; \end{cases} \quad (4)$$

$$\delta_T^E(y_{T-h}) = \delta_{T-h}^C(y_{T-h}) + \begin{cases} \sum_{i=0}^h \delta_{T-i}^E(y_{T-h}), & 0 \leq h \leq n, \\ \sum_{i=0}^n \delta_{T-h+i}^E(y_{T-h}), & n < h \leq T. \end{cases} \quad (5)$$

由  $h=0$  算起,体现误差反传.图 1 所示为  $m < n$  情况.当  $m > n$  时,计算公式不变.但是,无论哪种情况, $T$  必须大于  $m$  与  $n$  中大者.

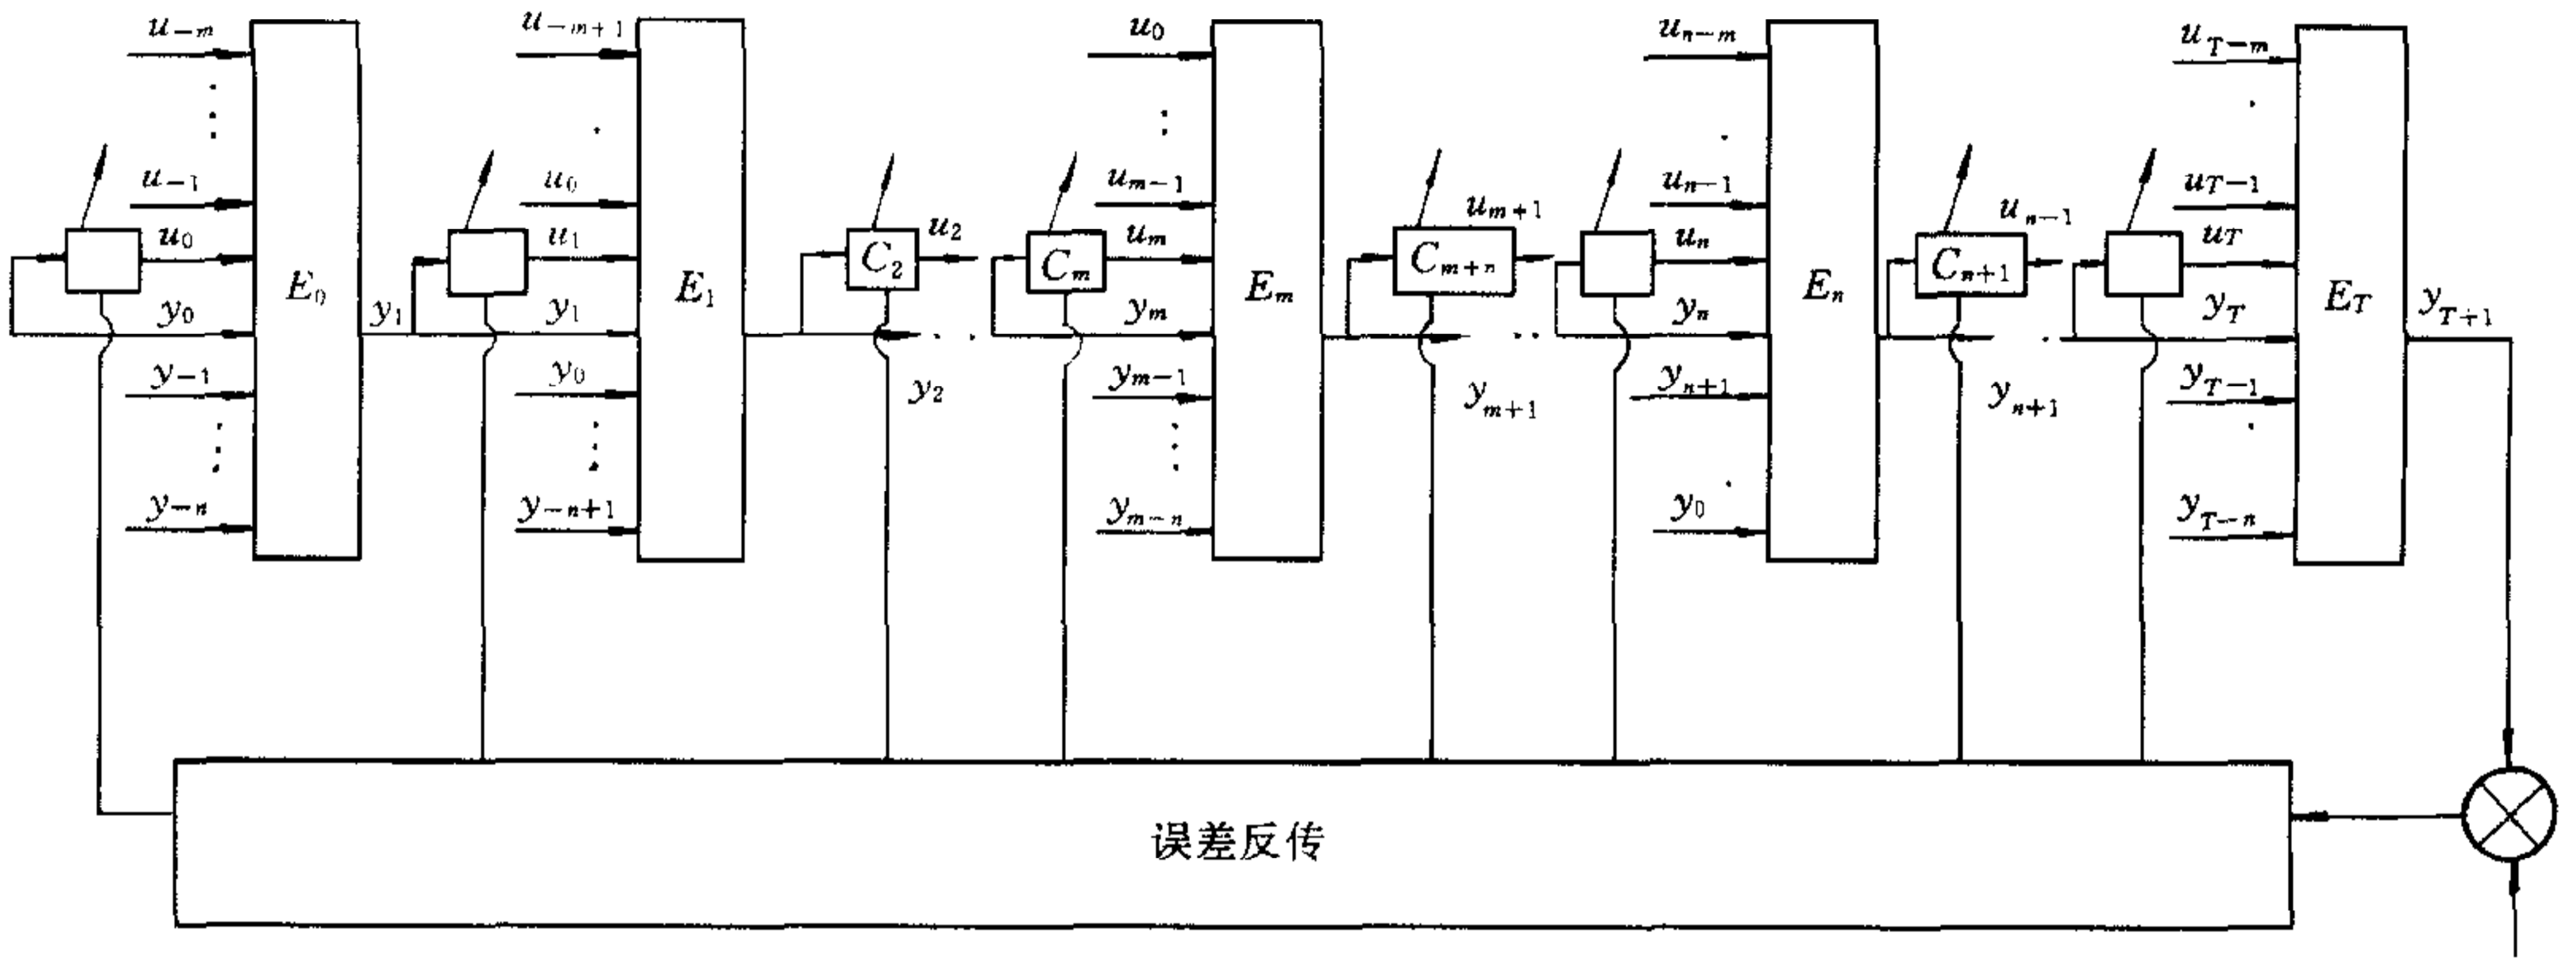


图 1 控制器网络训练结构

考虑约束控制下多目标终态控制问题.将指标函数变为

$$J' = \frac{1}{2} \left[ \alpha(y_d - y_{T+1})^2 + \beta \sum_{h=0}^T u_h^2 \right].$$

设控制量满足约束  $B \leq u_h \leq A. \quad (0 \leq h \leq T),$

令  $C_h$  网络输出层神经元作用函数为

$$u_h = f(net_h) = \frac{A - B}{1 + \exp(-net_h)} + B,$$

则可以推出,式(3)变化为  $\delta_T^E(y_{T+1}) = \alpha(y_d - y_{T+1}),$

式(4)变化为

$$\delta_{T-h}^E(u_{T-h}) = \left[ -\beta u_{T-h} + \begin{cases} \sum_{i=0}^h \delta_{T-i}^E(u_{T-h}), & 0 \leq h \leq m \\ \sum_{i=0}^m \delta_{T-h+i}^E(u_{T-h}), & m < h \leq T \end{cases} \right] \times (u_h - B) \left[ 1 - \left( \frac{u_h - B}{A - B} \right) \right],$$

式(5)不变.



## 4 应用及结论

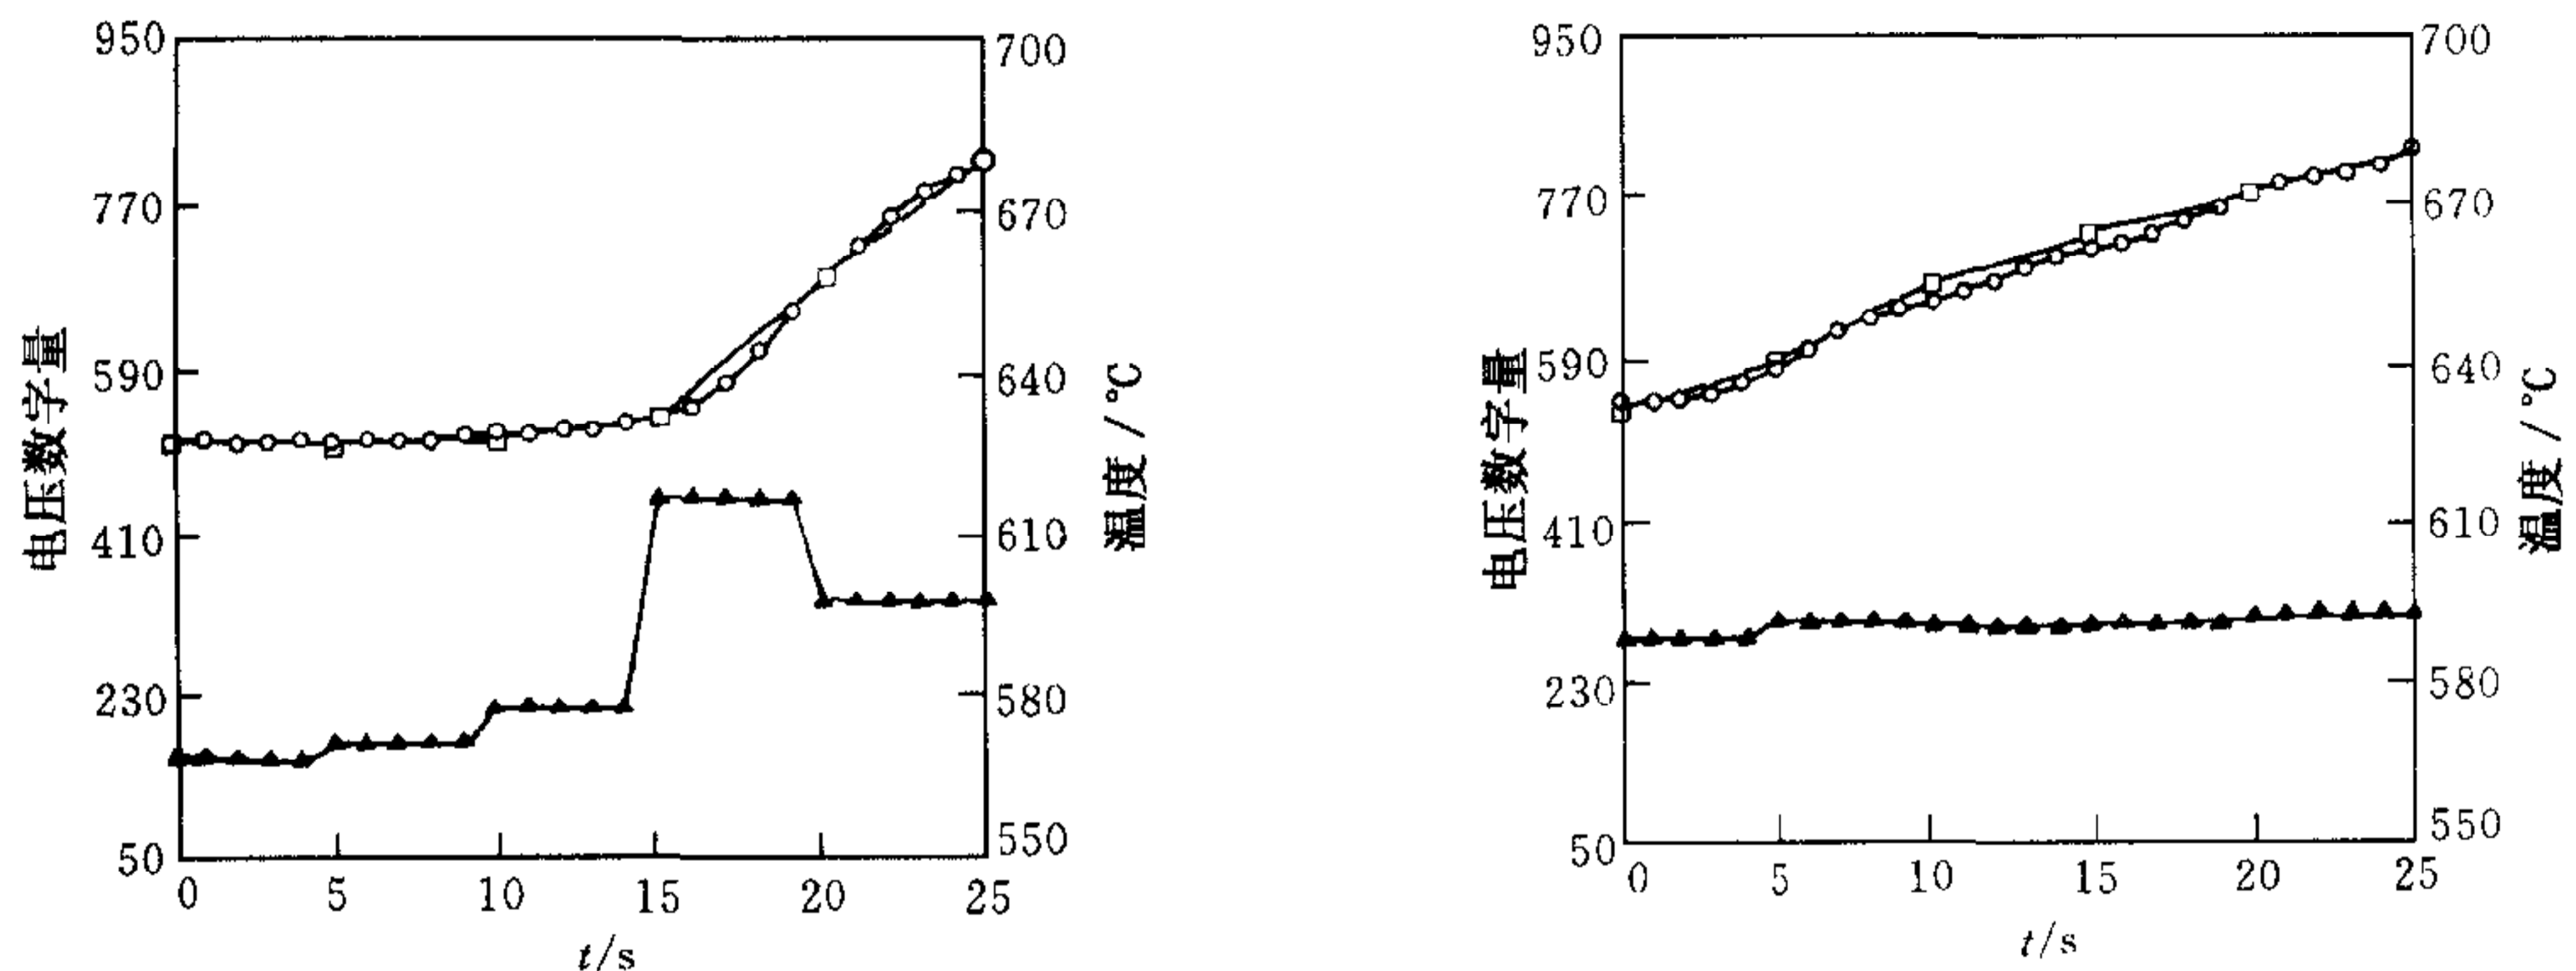
感应加热过程机理复杂,无法实现传统最优控制.采用神经网络自学习控制,可以实现温度智能控制.输入输出模型结构根据温度控制经验取为  $n=1, m=3$ .仿真器结构为  $\pi(4 \times 8 \times 4 \times 1)$ .用阶跃响应数据构成训练模式.仿真器线性训练学习因子为  $\eta_1=10^{-7}$ ,复合训练学习因子为  $\eta_2=10^{-8}$ .控制器结构为  $\pi(1 \times 4 \times 1)$ .时间步为 5.针对不同情况,进行升温控制实验.如:

- 1)  $y_0=626^\circ\text{C}, y_d=680^\circ\text{C}, \alpha=1, \beta=0$ ; 2)  $y_0=626^\circ\text{C}, y_d=680^\circ\text{C}, \alpha=1, \beta=50$ ;  
3)  $y_0=626^\circ\text{C}, y_d=680^\circ\text{C}, \alpha=1, \beta=50, B=0.2\text{V}, A=1.9\text{V}$ .

实验结果为:

- 1)  $y_d - y_{T+1}: 1.34^\circ\text{C}$ , 能量: 2.549; 2)  $y_d - y_{T+1}: 0.23^\circ\text{C}$ , 能量: 2.487(优);  
3)  $y_d - y_{T+1}: -0.26^\circ\text{C}$ , 能量: 2.624.

实验曲线见图 2.图中三角点为控制量,圆点为温度量,方点为仿真器输出量.



(a) 实验结果 2

(b) 实验结果 3

图 2 实验结果

从实验中发现,控制序列跳跃模式及幅度与仿真器训练模式差异较大时,仿真器误差较大,说明超出了泛化能力,出现了偏差.受约束控制时,优化效果有所下降.因此,实施神经网络自学习控制,应最大限度放宽控制量约束,并在较大范围内,采用多种训练模式进行训练,提高仿真器刻化实际对象程度,以获得较好控制效果.实验结果表明:神经网络自学习控制对于解决复杂工业过程优化控制问题具有一定意义.

## 参 考 文 献

- 1 Derrick H, Nguyen. Neural networks for self-learning control systems. *Control Syst. Mag.* 1990, (3): 18~23
- 2 朱刚. 一类点测控分布参数复杂工业过程反馈与智能控制应用研究[博士学位论文]. 西安: 西安交通大学研究生院, 1996

朱 刚 男, 博士, 副教授. 研究领域: 过程控制、神经网络控制、多媒体通信系统、ATM 网络流控.