

文章编号: 1000-8152(2008)05-0857-05

## 具有Hammerstein模型描述的非线性系统的 基于混合神经网络的预测控制

向微, 陈宗海, 盛捷

(中国科学技术大学 自动化系, 安徽 合肥 230027)

**摘要:** 本文针对多输入多输出Hammerstein模型提出了一种基于混合神经网络的模型预测控制策略, 控制器采用线性优化机构和高斯径向基神经网络串联。该策略不需要假设Hammerstein模型的非线性部分由多项式构成, 避免了已有研究在无根或重根情况下存在导致预测控制的优化特征丧失问题, 而采用混合神经网络则避免了采用传统神经网络拟合动态映射时存在的网络规模大和实时性差的不足。

**关键词:** Hammerstein模型; 多输入多输出系统; 混合神经网络; 模型预测控制

中图分类号: TP13 文献标识码: A

## A model-predictive control method based on hybrid neural networks for nonlinear systems described by Hammerstein model

XIANG Wei, CHEN Zong-hai, SHENG Jie

(Department of Automation, University of Science and Technology of China, Hefei Anhui 230027, China)

**Abstract:** A model-predictive control strategy based on hybrid neural networks for the multi-input and multi-output Hammerstein model is presented, which uses a linear optimal component and radial basis function neural networks in series. By this method, the nonlinear block is not limited to a polynomial equation, thus the requirement of real roots of the polynomial equation in traditional control designs is removed with no deterioration of the optimal performance. On the other hand, the hybrid neural networks are more efficient than the traditional neural networks which require complicated net structures in approximating dynamic mappings and show poor real-time performance.

**Key words:** Hammerstein model; multi-input and multi-output system; hybrid neural networks; model predictive control

### 1 引言(Introduction)

Hammerstein模型由非线性静态模型和线性动态模型串联构成, 相对线性模型, 它能更充分的描述以上系统在工作区上的整体动态特性<sup>[1]</sup>。同时相应控制问题不需要引入非线性优化, 从而可以避免NLP(nonlinear programming)问题。

常规Hammerstein控制策略包括以下3个步骤: 辨识Hammerstein模型; 利用线性模型预测策略, 获得中间控制变量; 解非线性方程以获得实际控制输入<sup>[2,3]</sup>。作为非线性逼近的另一常用工具, 神经网络在这一领域也有许多成果, 主要集中于研究系统为单输入单输出的情况<sup>[4,5]</sup>。

本文根据Hammerstein模型的特点, 提出了一种混合神经网络预测控制策略, 控制器由多变量线性优化机构和前向高斯径向基神经网络串联而成, 使得线性优化机构主要完成对动态性能以及时延的处理, 神经网络主要承担非线性静态逆映射的作用。

本文方法有以下特点: 非线性静态环节可以由广义基函数组成, 不要求只能是多项式, 这样可以采用与对象的先验非线性特征相匹配的基函数, 辨识和控制所需要的参数更少, 有利于提高模型辨识和控制的精度; 混合神经网络针对对象的特点合理的分配了控制器各部分的任务, 减小了应用时的网络规模, 训练简单, 使用方便; 离线训练好神经网络后, 每步控制循环在第3个环节只需做简单的基本运

收稿日期: 2007-02-07; 收修改稿日期: 2007-10-30.

基金项目: 国家自然科学基金资助项目(60575033).

算, 不需求解方程, 计算量小, 避免了求解方程时的无根和重根情况.

## 2 模型描述(Problem presentation)

Hammerstein模型的非线性系统由无记忆的非线性环节和动态线性环节串联构成, 如图1所示.

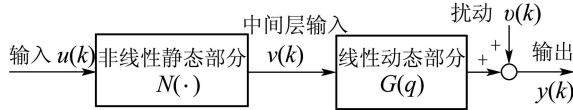


图1 Hammerstein模型

Fig. 1 Hammerstein model

图中输入输出关系可以表示为:

$$y(k) = G(k)N(u(k)) + v(k), \quad (1)$$

采用基函数来近似非线性部分如下:

$$v(k) = N(u(k)) = \sum_{i=1}^r d_i f_i(u(k)), \quad (2)$$

$f_i(\cdot) : \mathbb{R}^n \rightarrow \mathbb{R}^n (i = 1, 2, \dots, r)$  为已知非线性基函数,  $d_i \in \mathbb{R}^{n \times n} (i = 1, 2, \dots, r)$  为未知参数矩阵. 设线性部分  $G(q) \in H_2^{(m \times n)}$  空间, 可采用截断长度的Laguerre级数表达为以下形式<sup>[6]</sup>:

$$G(q) = \sum_{j=1}^p c_j L_j(q), \quad (3)$$

$\{L_j(q)\}_{j=1}^\infty$  为Laguerre级数,  $p$  为截断长度,  $c_j \in \mathbb{R}^{m \times n}, j = 1, 2, \dots, p$  为未知参数矩阵.

将式(2)(3)代入式(1), 得到:

$$y(k) = \sum_{j=1}^p \sum_{i=1}^r c_j d_i L_j(q) f_i(u(k)) + v(k), \quad (4)$$

本文采用如图2所示的混和神经网络控制器, 由两部分串联而成: 1) 根据辨识出的Hammerstein对象线性部分参数  $\hat{c}$  对线性部分设计的图2中的多变量线形优化结构; 2) 利用辨识的非线性部分的参数  $\hat{d}$  所训练的向基神经网络来拟合非线性部分的逆映射. 整个控制器的设计按以下步骤进行, 首先利用最小二乘法和奇异值分解辨识出两部分的参数  $\hat{c}$  和  $\hat{d}$ ; 然后采用线性模型预测控制原理对线性部分设计控制器, 得到中间层控制变量  $v^*(k)$ ; 最后采用正交最小二乘法训练神经网络.

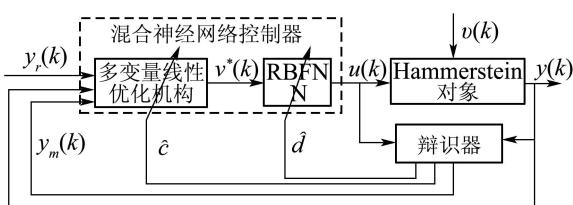


图2 Hammerstein系统混合神经网络控制结构图  
Fig. 2 Hybrid NN controller of Hammerstein model

对象辨识采用的模型结构由广义基函数组成, 参数辨识采用最小二乘法和奇异值分解<sup>[7]</sup>.

## 3 对象模型辨识(Identification of the Hammerstein model)

假设一个可用以上Hammerstein模型描述的实际系统, 其输入输出样本集为  $\{u(k), y(k)\}_{k=1}^N$ , 现用最小二乘法和奇异值分解估计  $c_j (j = 1, 2, \dots, p)$ ,  $d_i (i = 1, 2, \dots, r)$  的值. 定义:

$$l_{ij} = L_j(q) f_i(u(k)), \quad (5)$$

$u(k)$  代入式(5), 可以计算出  $l_{ji}(k), (i = 1, 2, \dots, r, j = 1, 2, \dots, p)$ , 记:

$$\phi(k) = [l_{11}^T(k), l_{12}^T(k), \dots, l_{1r}^T(k), l_{21}^T, \dots, l_{2r}^T, \dots, l_{pr}^T]^T, \quad (6)$$

$$\theta(k) = [c_1 d_1, c_1 d_2, \dots, c_1 d_r, c_2 d_1, \dots, c_2 d_r, \dots, c_p d_r]^T, \quad (7)$$

则式(4)可写为

$$y(k) = \theta^T \phi(k) + v(k), \quad (8)$$

定义:

$$\begin{cases} Y_N = [y^T(1), y^T(2), \dots, y^T(N)]^T, \\ V_N = [v^T(1), v^T(2), \dots, v^T(N)]^T, \\ \phi_N = [\phi^T(1), \phi^T(2), \dots, \phi^T(N)]^T, \end{cases} \quad (9)$$

由式(8)可得:

$$Y_N = \phi_N^T \theta + V_N, \quad (10)$$

转化为线性回归形式, 采用最小二乘法, 可求出:

$$\hat{\theta} = (\phi_N \phi_N^T)^{-1} \phi_N Y_N, \quad (11)$$

记矩阵:

$$\theta_{cd} = \begin{bmatrix} c_1 d_1 & c_1 d_2 & \dots & c_1 d_r \\ c_2 d_1 & c_2 d_2 & \dots & c_2 d_r \\ \vdots & \vdots & \ddots & \vdots \\ c_p d_1 & c_p d_2 & \dots & c_p d_r \end{bmatrix} = \begin{bmatrix} c_1 \\ c_2 \\ \vdots \\ c_p \end{bmatrix} \begin{bmatrix} d_1 \\ d_2 \\ \vdots \\ d_r \end{bmatrix}^T, \quad (12)$$

通过对  $\theta$  的估计  $\hat{\theta}$ , 可以获得  $\theta_{cd}$  的估计  $\hat{\theta}_{cd}$ . 此时利用以下原理, 可辨识出Hammerstein型的参数.

**定义 1** 矩阵  $\theta = (\theta_{ij})_{mp \times nr}$  的2-范数定义为:

$$\|\theta\|_2 = \sup_{w \neq 0} \frac{\|\theta w\|_2}{\|w\|_2}.$$

**引理 1** (奇异值分解(SVD))若  $\theta \in \mathbb{R}_{mp \times nr}$ , 则存在正交矩阵  $\alpha = [\alpha_1, \dots, \alpha_{mp}] \in \mathbb{R}_{mp \times mp}$  和  $\beta = [\beta_1, \dots, \beta_{nr}] \in \mathbb{R}_{nr \times nr}$ , 使

$$\alpha^T \theta \beta = \text{diag}\{\sigma_1, \dots, \sigma_\rho\}, \rho = \min\{mp, nr\}, \quad (13)$$

其中  $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_\rho \geq 0$ .

**推论1** 设 $\theta \in \mathbb{R}^{mp \times nr}$ 的奇异值分解由引理1给出, 如果 $\zeta < \text{rank } \theta$ 且 $\theta_\zeta = \sum_{\zeta} \sigma_i \alpha_i \beta_i^T$ , 那么<sup>[8]</sup>:

$$\min_{\text{rank } \tilde{\theta}=\zeta} \|\theta - \tilde{\theta}\|_2 = \|\theta - \theta_\zeta\|_2 = \sigma_\zeta + 1, \quad (14)$$

则将 $\hat{\theta}_{cd}$ 进行SVD分解, 则我们可以同时得到线形和非线性辨识结果(参数收敛性证明参考文献[7]):

$$[\hat{c}_1^T \hat{c}_2^T \cdots \hat{c}_p^T]^T = [\alpha_1 \alpha_2 \cdots \alpha_n]^T, \quad (15)$$

$$[\hat{d}_1 \hat{d}_2 \cdots \hat{d}_r] = \text{diag}\{\sigma_1, \dots, \sigma_n\} [\beta_1 \beta_2 \cdots \beta_n]^T. \quad (16)$$

#### 4 混和神经网络模型预测控制(Model predictive control based on hybrid neural networks)

利用以上获得的参数, 采用连续网络补偿方法<sup>[6]</sup>, 可推导出MIMO系统的状态空间模型:

$$\begin{cases} L(k+1) = \tilde{A}L(k) + \tilde{B}\tilde{v}(k), \\ y_m(k) = \hat{C}L(k), \end{cases} \quad (17)$$

其中:

$$\begin{aligned} \hat{A} &= \text{diag}\{\underbrace{A \cdots A}_n\}, \hat{B} = \text{diag}\{\underbrace{b \cdots b}_n\}, \\ \tilde{v}(k) &= \sum_{i=1}^r \hat{d}_i f_i[u(k)], \\ \hat{C} &= [\hat{c}_1 \hat{c}_2 \cdots \hat{c}_p], \end{aligned}$$

则原非线性系统求控制律 $\hat{u}(k)$ 的控制问题变成如上线性系统求中间控制律 $\tilde{v}(k)$ 的控制问题. 采用传统模型预测控制方法设计多变量线性优化机构. 预测步长为 $P$ , 控制步长为 $M$ , 可以得到系统的 $P$ 步模型输出为:

$$\begin{cases} Y_m(k+1) = H_o \bar{L}(k) + H_f \bar{V}(k), \\ Y_m(k+1) = [y_m^T(k+1) \ y_m^T(k+2) \ \cdots \ y_m^T(k+P)]^T, \\ \bar{L}(k) = [L^T(k) \ L^T(k+1) \ \cdots \ L^T(k+P-1)]^T, \\ \bar{V}(k) = [\hat{V}^T(k) \ \hat{V}^T(k+1) \ \cdots \ \hat{V}^T(k+M)]^T, \\ H_o = \begin{pmatrix} \hat{C}\tilde{A} \\ \hat{C}\tilde{A}^2 \\ \vdots \\ \hat{C}\tilde{A}^P \end{pmatrix}, \\ H_f = \begin{pmatrix} \hat{C}\tilde{B} & & & 0 \\ \hat{C}\tilde{A}\tilde{B} & \hat{C}\tilde{B} & & \\ \vdots & \vdots & \ddots & \\ \hat{C}\tilde{A}^{M-1}\tilde{B} & \hat{C}\tilde{A}^{M-2}\tilde{B} & \cdots & \hat{C}\tilde{B} \\ \vdots & \vdots & \cdots & \cdots \\ \hat{C}\tilde{A}^{P-1}\tilde{B} & \hat{C}\tilde{A}^{P-2}\tilde{B} & \cdots & \hat{C}\tilde{A}^{P-M}\tilde{B} \end{pmatrix}. \end{cases} \quad (18)$$

考虑到模型误差与外界干扰, 对 $Y_m(k+1)$ 进行如下的反馈校正:

$$\hat{Y}_m(k+1) = Y_m(k+1) + K_a[y(k) - y_m(k)], \quad (19)$$

$y(k)$ 与 $y_m(k)$ 分别为 $k$ 时刻对象的实际输出与模型的输出,  $K_a$ 为校正增益矩阵, 一般取 $K_a = [1 \ \cdots \ 1]_{P+1}^T$ . 取性能指标为:

$$J = \|Y_r(k+1) - \hat{Y}_m(k+1)\|_Q^2 + \|\Delta \bar{V}(k)\|_R^2, \quad (20)$$

其中:  $Y_r(k+1)$ 为目标输出序列,  $Q, R$ 分别为预测和控制加权矩阵. 记:

$$K_{\Delta v} = \underbrace{[I_n \ 0]}_{n \times nM} (H_f^T Q H_f + R)^{-1} H_f^T Q, \quad (21)$$

得到控制律增量为:

$$\begin{aligned} \Delta \tilde{v}(k) &= K_{\Delta v}[Y_r(k+1) - K_a y(k) + \\ &\quad K_a y_m(k) - H_o \bar{L}(k) - H_f \bar{V}(k-1)], \end{aligned} \quad (22)$$

则可以计算出这一步控制中期望的中间信号 $\tilde{v}(k)$ .

设非线性部分可逆, 采用径向基神经网络拟合非线性静态部分的逆映射, 利用已辨识数据 $\hat{d}_i (i = 1, 2, \dots, r)$ , 可算出 $\tilde{v}(k)$ , 神经网络的训练样本输入为 $\tilde{v}(k)$ , 目标输出为 $u(k) (k = 1, 2, \dots, N)$ . 训练过程采用正交最小二乘算法, 利用正交变换来优选中心节点. 训练完成以后, 设隐含层采用 $S$ 个神经元, 其中心矢量和宽度分别为 $\vartheta_i, \chi_i, i = 1, 2, \dots, S$ , 输出层权值为 $w_i, i = 1, 2, \dots, S$ , 阈值为 $\psi$ , 求出实际控制律为:

$$\hat{u} = \sum_{i=1}^S W_s e^{-\frac{\|\tilde{v}(k) - \vartheta_i\|^2}{2\chi_i^2}} - \psi, \quad (23)$$

综上, 神经网络中的线性优化机构起到了处理动态和时延的作用, RBF神经网络仅需映射非线性静态关系, 当RBF神经网络恰当训练后, 可以以任意精度逼近闭域上的非线性函数<sup>[9]</sup>, 进而按文[10,11]中方法来选择保证系统闭环稳定性的中间信号, 然后充分训练神经网络, 获得保证整个系统的稳定性实际控制率.

#### 5 仿真实验和结果分析(Simulation experiment and result analysis)

以上方法在如下对象上进行了仿真实验, 此Hammerstein模型具体描述见参考文献[9], 对象线性部分关系为:

$$\begin{aligned} \begin{bmatrix} y_1(k) \\ y_2(k) \end{bmatrix} &= \begin{bmatrix} 0.5 & -0.1 \\ 0.8 & -0.7 \end{bmatrix} \begin{bmatrix} y_1(k-1) \\ y_2(k-1) \end{bmatrix} + \begin{bmatrix} -0.3 & 0.2 \\ 0.9 & -0.5 \end{bmatrix} \\ &\quad \begin{bmatrix} y_1(k-2) \\ y_2(k-2) \end{bmatrix} + \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} y_1(k-2) \\ y_2(k-2) \end{bmatrix}, \end{aligned} \quad (24)$$

非线性部分关系为:

$$\begin{cases} v_1(k) = \frac{1 - e^{-(u_1(k) + u_2(k))}}{1 + e^{-(u_1(k) + u_2(k))}}, \\ v_2(k) = 0.2(u_1(k) - 0.3)^3 + 0.5u_2(k). \end{cases} \quad (25)$$

利用本文中的算法,采用以下两个基函数:

$$\begin{cases} f_1\left(\begin{bmatrix} u_1(k) \\ u_2(k) \end{bmatrix}\right) = \begin{bmatrix} 1 \\ 1 + e^{-(u_1(k) + u_2(k))} \\ u_2(k) \end{bmatrix}, \\ f_2\left(\begin{bmatrix} u_1(k) \\ u_2(k) \end{bmatrix}\right) = \begin{bmatrix} 1 \\ (u_1(k) - 0.3)^3 \end{bmatrix}, \end{cases} \quad (26)$$

对以上对象进行控制,跟踪方波结果如图3所示。

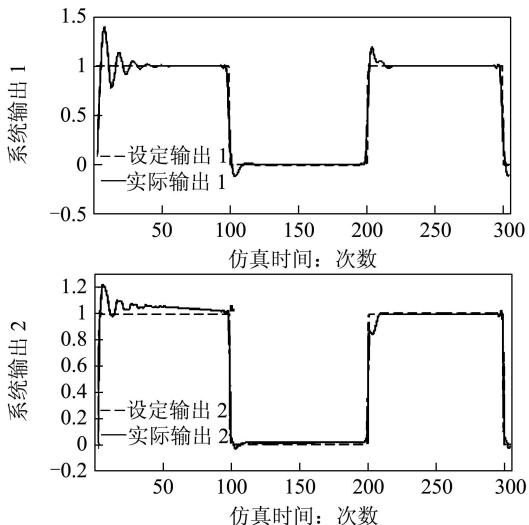


图3 采用本文方法控制系统跟踪方波

Fig. 3 Tracking performance of the method in this paper

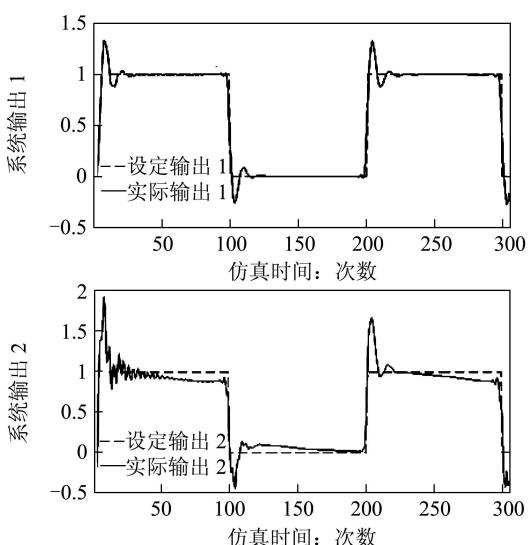


图4 采用文[7]中方法控制系统跟踪方波

Fig. 4 Tracking performance of the method in Ref[7]

相关参数值如下: 基函数个数  $r = 2$ , Laguerre级数截断长度  $p = 2$ , 预测步长  $P = 8$ , 控制步

长  $M = 6$ , 参考轨迹柔化因子为 0.72。由于非线性部分采用广义基的形式,故传统算法中假设非线性部分为多项式的算法此处无法直接使用,若将非线性部分做多变量泰勒展开后取有限项,会影响辨识的精度,也就必然影响控制的精度;采用本算法需要辨识的参数仅有  $c_1, c_2, d_1, d_2$  4 项,而泰勒展开后的多项式需要保留足够项,采用传统算法要辨识的参数更多,辨识和控制过程的计算更复杂,计算量更大。采用文[7]中的迭代算法在同样的参数时控制效果如图4所示。由此可以看出采用本文中算法超调时间更短,控制精度更高,能够有效的控制多变量系统。

## 6 结论(Conclusion)

本文提出了采用串联神经网络控制多输入多输出模型的方法。这一方法不需假定非线性部分为多项式形式,因此更能适应广泛的实际对象,特别是当对象部分非线性特性已知时,将大大减少需要辨识的参数,简化控制器,提高控制精度。传统研究中,每步优化过程中一般需要完成解方程操作,可能出现无根和重根情况,且计算复杂,而采用本文算法,当神经网络训练完成后,计算控制率时,只需要完成有限次高斯映射和乘法以及一次加法,计算量小,更适合实时操作。目前采用的混合控制器是离线设计的,但由于系统参数辨识过程主要依赖最小二乘法,控制器设计主要采用正交最小二乘法,因此控制器参数的在线调整是非常可行的,这将是今后研究的工作之一。

## 参考文献(References):

- [1] FRUZZETTI K P, PALAZOGLU A, MCDONALD K A. Nonlinear model predictive control using Hammerstein models[J]. *Journal of Process Control*, 1997, 7(1): 31 – 43.
- [2] 黄道平, 朱学峰, 周其节. 基于广义Hammerstein模型的多变量非线性预测控制[J]. 暨南大学学报(自然科学版), 1998, 19(1): 13 – 19.  
(HUANG Daoping, ZHU Xuefeng, ZHOU Qijie. Multivariable nonlinear predictive control based on generalized Hammerstein model[J]. *Journal of Jinan University (Natural Science)*, 1998, 19(1): 13 – 19.)
- [3] 徐湘元, 毛宗源. 基于Hammerstein模型预测控制的分析与研究[J]. 控制理论与应用, 2000, 17(4): 529 – 532.  
(XU Xiangyuan, MAO Zongyuan. Analysis and research of predictive control based on Hammerstein model[J]. *Control Theory & Applications*, 2000, 17(4): 529 – 532.)
- [4] TAN Y H, CAUWENBERGHE A V. Nonlinear one-step-ahead control using neural networks[J]. *Control Strategy and Stability Design, Automatica*, 1996, 32(12): 1701 – 1706.
- [5] 王雷, 陈宗海, 张海涛, 等. 复杂过程对象混合建模策略的研究[J]. 系统仿真学报, 2004, 16(8): 1794 – 1804.  
(WANG Lei, CHEN Zonghai, ZHANG Haitao, et al. Study of hybrid modeling strategy for complex processes[J]. *Journal of System Simulation*, 2004, 16(8): 1794 – 1804.)
- [6] MAKILA P M. Approximation of stable systems by laguerre filters[J]. *Automatica*, 1990, 26(2): 333 – 345.

- [7] GOMEZ J C, BAEYENS E. Identification of block-oriented nonlinear systems using orthonormal bases[J]. *Journal of Process Control*, 2004, 14(6): 685 – 697.
- [8] GOLUB G, VAN LOAN C. 矩阵计算[M]. 廉庆荣, 邓健新, 刘秀兰, 译. 大连: 大连理工大学出版社, 1988: 19 – 22.  
(GOLUB G, VAN LOAN C. *Matrix Computations*[M]. LIAN Qingsong, DENG Jianxin, LIU Xiulan, trans. Dalian: Dalian University of Technology Press, 1988: 19 – 22.)
- [9] PARK J, SANDBERG I W. Approximation and radial-basis-function networks[J]. *Neural Computation*, 1993, 5(2): 246 – 257.
- [10] RAWLINGS J B, MUSKE K R. Stability of constrained receding horizon control[J]. *IEEE Transactions on Automatic Control*, 1993, 38(10): 1512 – 1516.
- [11] CLARKE D W, SCATTOLINI R. Constrained receding-horizon predictive control[J]. *Proceedings IEEE*, 1991, 138(4): 347 – 354.

### 作者简介:

向 微 (1980—), 女, 硕博连读生, 研究方向为复杂系统建模与控制;

陈宗海 (1963—), 男, 教授, 博士生导师, 中国自动化学会理事, 中国系统仿真学会常务理事, 研究方向为复杂系统建模、仿真与控制、模式识别与智能系统、量子控制等, E-mail: chenzh@ustc.edu.cn;

盛 捷 (1972—), 男, 讲师, 研究方向为模复杂系统建模与控制.

## 下期要目

基于量子位Bloch坐标的量子遗传算法及其应用	李盼池
LuGre摩擦模型对伺服系统的影响与补偿	周金柱, 段宝岩, 黄 进
6R机器人实时逆运动学算法研究	刘松国, 朱世强, 李江波, 王宣银
基于情感与环境认知的移动机器人自主导航控制	张惠娣, 刘士荣
含有驱动器模型的移动机器人自适应跟踪控制	岳李勇, 谢 巍
多线切割机速度同步系统的自适应逆控制	张义兵, 戴瑜兴, 汤 睿
快速路入口匝道的非参数自适应迭代学习控制	池荣虎, 侯忠生, 隋树林
调节 $L_2$ 增益抑制耦合发电机组的混沌现象	谭拂晓, 关新平, 刘德荣, 罗小元
基于支持向量机的非线性内模解耦控制	宋夫华, 郑恩辉
一类仿射非线性系统的自适应神经网络输出反馈变结构控制	杜红彬, 余昭旭
具有控制时滞的离散系统的无抖振滑模控制	唐功友, 吕彬彬, 董 瑞
参数不确定柔性机械手的终端滑模控制	王艳敏, 冯 勇
基于等价空间的多速率数据采样系统快速残差的产生	刘云霞, 钟麦英
随机时滞Lurie系统的鲁棒 $H_\infty$ 和 $L_2-L_\infty$ 指数控制	陈 云, 薛安克, 鲁仁全, 苏宏业
Delta算子描述系统的非脆弱 $H_\infty$ 滤波器设计	王 武, 郭祥贵, 冉华军, 杨富文
直流电机双闭环调速系统(DLM)的建模与辨识	李永龙, 李祖枢, 王 牛
基于反步自适应控制的伺服系统齿隙补偿	马艳玲, 黄 进, 张 丹