第 22 卷 第 8 期 控 制 与 决 策 2007 年 8 月
Vol. 22 No. 8 Control and Decision Aug. 2007

文章编号: 1001-0920(2007)08-0922-05

基于并行支持向量机的多变量非线性模型预测控制

包哲静[a], 皮道映[b], 孙优贤[b]
(浙江大学 a. 电气工程学院, b. 工业控制研究所, 杭州 310027)

摘 要: 提出一种基于并行支持向量机的多变量系统非线性模型预测控制算法. 首先, 通过考虑输入、输出间的耦合, 建立基于并行支持向量机的多步预测模型; 然后, 将该模型用于非线性预测控制, 提出新的适用于并行预测模型的反馈校正策略, 得到最优控制律. 连续搅拌槽式反应器(CSTR)的控制仿真结果表明, 该算法的性能优于基于并行神经网络的非线性模型预测控制和基于集成模型的非线性模型预测控制.

关键词: 非线性模型预测控制; 并行支持向量机; 多变量系统; 多步预测模型
中图分类号: TP273 **文献标识码**: A

Multivariable nonlinear model predictive control based on parallel support vector machines

BAO Zhe-jing[a], *PI Dao-ying*[b], *SUN You-xian*[b]
(a. College of Electrical Engineering, b. Institute of Industrial Process Control, Zhejiang University, Hangzhou 310027, China. Correspondent: BAO Zhe-jing, E-mail: zjbao@ipc.zju.edu.cn)

Abstract: A nonlinear model predictive control algorithm based on parallel support vector machines for multivariable systems is presented. Multi-step predictive models based on parallel support vector machines are established by considering the coupling effects among outputs and inputs. Then, the predictive models are applied to nonlinear predictive control, a novel feedback correction strategy suitable for the models is presented, and optimal predictive control law is obtained. Simulation results of CSTR control show that the presented algorithm has better performance than nonlinear model predictive control based on parallel neural networks and integrating model.

Key words: Nonlinear model predictive control; Parallel support vector machines; Multivariable systems; Multi-step predictive models

1 引 言

工业对象大多是多变量、强非线性系统, 因此多变量系统的非线性模型预测控制(NMPC)已成为预测控制研究的热点. 模型的好坏对控制性能有重大的影响, 当前非线性过程建模问题已成为抑制 NMPC 技术发展的瓶颈之一. 近年来, 许多模型被用于 NMPC, 如 Hammerstein, Wiener, Volterra 模型[1], Takagi-Sugeno (T-S) 模糊模型[2], 神经网络(NN)模型[3]和集成模型(IM)[4]. 上述方法中, Hammerstein, Wiener, Volterra 模型只能用于特定过程; T-S 模型高度依赖先验知识; NN 模型易陷入局部最优解[5]; 集成模型辨识过程复杂且控制要借助中间变量.

支持向量机(SVM)是回归的强有力工具[6], 已有基于 SVM 的 NMPC 研究[5], 但很少涉及多变量系统的多步预测控制. 研究多变量系统的多步预测控制需考虑的问题主要有: 1) SVM 回归是从 SVM 分类理论推广而来, 所以传统 SVM 回归只适用于多输入单输出系统, 如何建立多输入多输出系统基于 SVM 的预测模型? 2) 怎样构造充分表达系统非线性、精确的 SVM 多步预测模型? 3) 由于构成每个输出分量模型的支持向量不尽相同, 如何将它们集成为一个向量形式?

本文提出一种基于并行支持向量机的多变量系统非线性模型预测控制算法, 仿真结果表明了该算法的有效性. 文中 SVM 参数的意义详见文献[6].

2 多变量系统多步 NMPC 简介

考虑如下具有输入向量 $u \in R^n$, 输出向量 $y \in$

收稿日期: 2006-05-18; **修回日期**: 2006-08-09.
基金项目: 国家 973 计划项目(2002CB312200); 国家自然科学基金项目(60574019).
作者简介: 包哲静(1974 —), 女, 浙江乐清人, 博士生, 从事支持向量机建模、预测控制等研究; 孙优贤(1940 —), 男, 浙江诸暨人, 教授, 博士生导师, 中国工程院院士, 从事复杂过程控制研究.

R^m 的未知非线性多变量系统:

$$\begin{aligned}&y(k+1)=\\&g[y(k),\cdots,y(k-n_y+1),\\&u(k),\cdots,u(k-n_x+1)].\end{aligned}\tag{1}$$

由于被控对象未知,构造对象的多步预测模型,寻找最优的控制增量 $\Delta u(k+j)$ $(j=0,\cdots,H_u-1)$,使模型预测控制(MPC)的二次型目标函数最小,即

$$\min J=\sum_{i=1}^{H_p}\|y_p(k+i|k)-y_s(k+i)\|_{Q(i)}^2+\sum_{j=0}^{H_u-1}\|\Delta u(k+j)\|_{R(j)}^2.\tag{2}$$

其中:$y_p(k+i|k)$ 是基于预测模型的未来输出,$y_s(k+i)$ 是输出设定值,$Q(i)$ 和 $R(j)$ 是已知的权重矩阵,$Q(i)=\mathrm{diag}\{q_{i,1},\cdots,q_{i,m}\}$,$R(j)=\mathrm{diag}\{r_{j,1},\cdots,r_{j,n}\}$.

建立多步预测模型往往采取递归的方法,即 i 步预测模型依赖于 $i-1$ 步预测模型的输出,当预测时域较大时,会产生较大的累积误差,势必会影响控制效果.

另外,传统 SVM 回归中输出是一维的. 因此,许多文献只考虑单输出的情况,认为高维输出分量间彼此独立,这意味着控制前要进行解耦,而复杂系统的解耦通常非常困难,且并非所有多变量系统都能实现解耦.

3　基于并行 SVMs 的多变量系统多步 NMPC

系统结构如图 1 所示,主要包括 i 步 SVM 预测模型及其在线修正和预测控制器,其中 H_p 个并行的 SVM 预测模型相互独立,因此没有误差累积. 为简化推导过程,每个预测模型的训练样本个数相同.

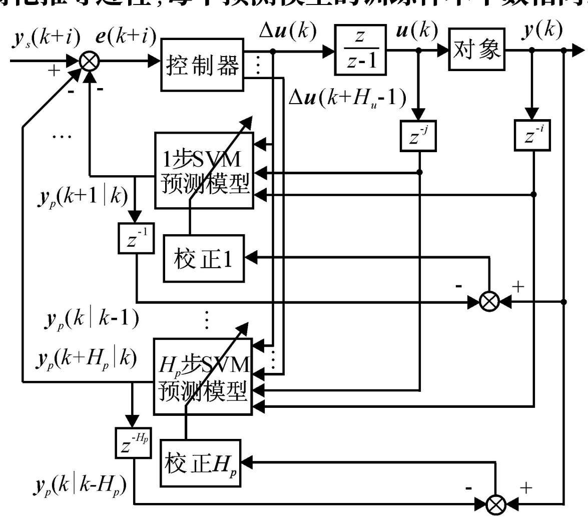

图 1　基于并行 SVMs 的多变量系统多步 NMPC 结构

SVMs-NMPC 算法步骤:首先离线建立基于并行 SVMs 的 i 步预测模型 $(i=1,\cdots,H_p)$,将预测输出表示为控制时域内的未知输入增量和已知输入输出量的函数;然后将其代入预测控制目标函数(2)中,此时目标函数中只有控制时域内的输入增量未知;再将目标函数对该未知量的导数置为零而得到输入增量,从而得到当前时刻的最优控制律.

3.1　基于并行 SVMs 的多变量系统多步预测模型

由于 $\Delta u(k)=u(k)-u(k-1)$,根据式(1)可得到

$$\begin{aligned}&y(k+i)=\\&f^i[y(k),\cdots,y(k-n_y+1),\Delta u(k+i-1),\\&\cdots,\Delta u(k),u(k-1),\cdots,u(k-n_x+1)].\end{aligned}\tag{3}$$

显然,k 时刻的提前 i 步输出值是最新已知的 n_y 个输出、最新已知的 n_x-1 个输入和 i 个未知的未来输入增量的函数. 其中已知量部分完全相同,这有利于构造相互独立的多步预测模型.

构造 i 步预测器时,输出分量根据样本分别拟合. 式(2)中的输出是向量,但构成每个输出分量模型的支持向量不同,通常只考虑支持向量的 SVM 表达式不适用. 因此,推导时所有样本都应考虑,而在程序实现时则只考虑支持向量,可使在线计算量大大减少.

考虑输入输出耦合,SVM 回归模型为

$$\begin{aligned}&y_j(k+i)=\\&f_{\mathrm{SVM}}^{i,j}[y(k),\cdots,y(k-n_y'+1),\Delta u(k+i-1),\\&\cdots,\Delta u(k),u(k-1),\cdots,u(k-n_x'+1)].\end{aligned}\tag{4}$$

其中:$j=1,\cdots,m$;$f_{\mathrm{SVM}}^{i,j}$ 是输出分量 $y_j(k+i)$ 的 SVM 非线性模型;n_y' 和 n_x' 依赖于近似精度.

通过建模得到拟合 $y_j(k+i)$ 的解向量 $a_j^{(i)}=[a_{j,1}^{(i)},\cdots,a_{j,\mathrm{num}}^{(i)}]$(num 为样本个数)和标量 $b_j^{(i)}$. 向量 $a_j^{(i)}$ 中,对应支持向量的分量非零,其余为零. 定义矩阵

$$A^{(i)}=\begin{bmatrix}a_{1,1}^{(i)}&\cdots&a_{1,\mathrm{num}}^{(i)}\\\cdots&\ddots&\cdots\\a_{m,1}^{(i)}&\cdots&a_{m,\mathrm{num}}^{(i)}\end{bmatrix}.$$

因此,时刻 k 基于二次多项式核函数 SVM 的输出向量 i 步预测值为

$$\begin{aligned}&y_{\mathrm{SVM}}(k+i|k)=\\&\sum_{l=1}^{\mathrm{num}}a_l^{(i)}(S_l^{(i)}\cdot I_{k+i}+1)^2+b^{(i)}=\\&\sum_{l=1}^{\mathrm{num}}a_l^{(i)}\Big(C_l^{(i)}+\sum_{j=0}^{i-1}\Delta u(k+j)\cdot S_{l,j}^{(i)}\Big)^2+b^{(i)}.\end{aligned}\tag{5}$$

其中:$b^{(i)}=[b_1^{(i)},\cdots,b_m^{(i)}]^{\mathrm{T}}$,$a_l^{(i)}$ 是矩阵 $A^{(i)}$ 的列向量,$S_l^{(i)}$ 是构造 $y_{\mathrm{SVM}}(k+i|k)$ 的样本输入向量. 定义

$$\begin{aligned}I_{k+i}'=&[y^{\mathrm{T}}(k),\cdots,y^{\mathrm{T}}(k-n_y'+1),\\&u^{\mathrm{T}}(k-1),\cdots,u^{\mathrm{T}}(k-n_x'+1)]^{\mathrm{T}},\end{aligned}$$

$$I_{k+i} = [y^T(k), \cdots, y^T(k - n_y' + 1), \Delta u^T(k + i - 1), \cdots, \Delta u^T(k), u^T(k - 1), \cdots, u^T(k - n_x' + 1)]^T.$$

$S_{l,j}^{(i)}$ 是构造 $y_{SVM}(k + i \mid k)$ 的样本 l 输入向量中与 I_{k+i} 中 $\Delta u^T(k + j)$ 对应的序列, $S_l^{(i)\prime}$ 是构造 $y_{SVM}(k + i \mid k)$ 的样本 l 中除去输入增量后的序列. $C_l^{(i)}$ 定义为

$$C_l^{(i)} = S_l^{(i)\prime} \cdot I_{k+i}' + 1. \tag{6}$$

不少非线性系统可采用基于二次多项式核函数 SVM 的模型近似,有较高的精度,且表达式相对简单,推导过程较为容易,模型偏差可通过反馈有效抑制;而基于高斯核函数 SVM 的模型虽然精度较前者高,但推导过程难度增加很多,同时求取控制律的在线计算时间加长,不能及时控制快速采样的对象;基于线性核 SVM 的模型尽管有更简单的表达式,但对复杂系统的拟合能力较差,影响控制性能.

3.2 优化 MPC 目标函数

MPC 通过反馈克服模型偏差和抗干扰. 图 1 中各预测模型间相互独立,且各预测模型当前最新的对象/模型偏差可求出,因此时刻 k 的 i 步预测模型可用最新的输出 $y(k)$ 与最新已知的 i 步预测模型输出 $y_{SVM}(k \mid k - i)$ 之间的偏差来修正. 于是,有下式成立:

$$y_p(k + i \mid k) = y_{SVM}(k + i \mid k) + H(i)[y(k) - y_{SVM}(k \mid k - i)], \tag{7}$$

其中 $H(i)$ 为误差校正矩阵,取为单位阵.

引理 1 非线性多变量系统基于并行二次多项式核函数 SVMs 的最优预测控制增量 $\Delta u_{opt}(k)$ 为方程组 $\{J_{p,j}' = 0$ 的解. 其中

$$J_{p,j}' = 2\sum_{i=p+1}^{H_p}\Big\{\sum_{q=1}^{m}\Big[2\sum_{l=1}^{nsv_{i,q}} a_{l,q}^{(i)} f_l^{(i)} S_{l,p,j}^{(i)}\Big] \times \Big[\sum_{l=1}^{nsv_{i,q}} a_{l,q}^{(i)} f_l^{(i)2} + g_q^{(i)}\Big] q_{q,i}\Big\} + 2 r_{p,j} \Delta u_j(k + p),$$

$$p = 0, \cdots, H_u - 1,\ j = 1, \cdots, n, \tag{8}$$

$nsv_{i,q}$ 为输出分量 $y_q(k + i \mid k)$ 的 SVM 模型支持向量个数,

$$f_l^{(i)} = C_l^{(i)} + \sum_{j=0}^{\min(i-1, H_u-1)} \Delta u(k + j) \cdot S_{l,j}^{(i)},$$

$$g_q^{(i)} = b_q^{(i)} + e_q(k \mid k - i) - y_{s,q}(k + i).$$

证明 当 $H_u < H_p$ 时, $\Delta u(k + j) = \mathbf{0}$, $j \geq H_u$, 则式(5) 改为

$$y_{SVM}(k + i \mid k) = \sum_{l=1}^{num} a_l^{(i)} (S_l^{(i)} \cdot I_{k+i} + 1)^2 + b^{(i)} =$$

$$\sum_{l=1}^{num} a_l^{(i)} \Big(C_l^{(i)} + \sum_{j=0}^{\min(i-1, H_u-1)} \Delta u(k + j) \cdot S_{l,j}^{(i)}\Big)^2 + b^{(i)}. \tag{9}$$

式(9) 中只有 $\Delta u(k + j)\ (0 \leq j \leq \min(i - 1, H_u - 1))$ 未知. 记 $\Delta U = [\Delta u^T(k), \cdots, \Delta u^T(k + H_u - 1)]^T$. 式(2) 有最小值的必要条件是:设

$$\frac{\partial J}{\partial \Delta U} = \begin{bmatrix} \dfrac{\partial J}{\partial \Delta u(k)} \\ \cdots \\ \dfrac{\partial J}{\partial \Delta u(k + H_u - 1)} \end{bmatrix} = \mathbf{0},$$

而

$$\frac{\partial J}{\partial \Delta u(k + p)} = 2\sum_{i=p+1}^{H_p} \frac{\partial y_p^T(k + i \mid k)}{\partial u(k + p)} Q(i)[y_p(k + i \mid k) - y_s(k + i)] + 2R(p)\Delta u(k + p). \tag{10}$$

根据式(7) 和(9) 得

$$\frac{\partial y_p^T(k + i \mid k)}{\partial \Delta u(k + p)} = \begin{bmatrix} 2\sum_{l=1}^{num} a_l^{(i)T}\Big(C_l^{(i)} + \sum_{j=0}^{\min(i-1, H_u-1)} \Delta u(k + j) \cdot S_{l,j}^{(i)}\Big) S_{l,p,1}^{(i)} \\ 2\sum_{l=1}^{num} a_l^{(i)T}\Big(C_l^{(i)} + \sum_{j=0}^{\min(i-1, H_u-1)} \Delta u(k + j) \cdot S_{l,j}^{(i)T}\Big) S_{l,p,n}^{(i)} \end{bmatrix}_{n*m}.$$

将上式代入式(10) ,整理得

$$\frac{\partial J}{\partial u(k + p)} = \begin{bmatrix} 2\sum_{i=p+1}^{H_p}\Big\{\sum_{q=1}^{m}\Big[2\sum_{l=1}^{num} a_{l,q}^{(i)} f_l^{(i)} S_{l,p,1}^{(i)}\Big] \times \Big[\sum_{l=1}^{num} a_{l,q}^{(i)} f_l^{(i)2} + g_q^{(i)}\Big] q_{i,q}\Big\} + 2 r_{p,1}\Delta u_1(k + p) \\ \cdots \\ 2\sum_{i=p+1}^{H_p}\Big\{\sum_{q=1}^{m}\Big[2\sum_{l=1}^{num} a_{l,q}^{(i)} f_l^{(i)} S_{l,p,n}^{(i)}\Big] \times \Big[\sum_{l=1}^{num} a_{l,q}^{(i)} f_l^{(i)2} + g_q^{(i)}\Big] q_{i,q}\Big\} + 2 r_{p,n}\Delta u_n(k + p) \end{bmatrix}. \tag{11}$$

其中

$$f_l^{(i)} = C_l^{(i)} + \sum_{j=0}^{\min(i-1, H_u-1)} \Delta u(k + j) \cdot S_{l,j}^{(i)},$$

$$g_q^{(i)} = b_q^{(i)} + e_q(k \mid k - i) - y_{s,q}(k + i).$$

矩阵 $A^{(i)}$ 中对应非支持向量的分量都为零,所以式(11) 中的样本数 num 可变为对应的支持向量数 $nsv_{i,q}$. □

注 1 方程组 $\{J_{p,j}' = 0$ 是关于未知控制律的 $n * H_u$ 元三次方程组,用 Matlab 优化工具箱中的

fsolve 函数求解.

4　仿真研究

以文献[4]研究的连续搅拌槽式反应器(CSTR)来验证算法 SVMs-NMPC 的有效性,并与算法 NNs-NMPC 和 IM-NMPC[4] 进行对比.

CSTR 过程由一阶非线性微分方程组描述[4]:

$$\begin{cases} \dfrac{\mathrm{d}C_a}{\mathrm{d}t} = \dfrac{q}{v}(C_{af} - C_a) - k_0 C_a \exp\left(-\dfrac{E}{RT}\right), \\ \dfrac{\mathrm{d}T}{\mathrm{d}t} = \dfrac{q}{v}(T_f - T) + \dfrac{(-\Delta H) k_0 C_a}{\rho C_p} \exp\left(-\dfrac{E}{RT}\right) + \\ \qquad \dfrac{\rho_c C_{pc}}{\rho C_p v} q_c \left[1 - \exp\left(-\dfrac{hA}{q_c \rho_c C_{pc}}\right)\right](T_{cf} - T). \end{cases}$$

其中:C_a 和 T 为输出,q_c 和 q 为输入,采样周期 $t_s = 0.1$ min. 这是一个二输入二输出、严重关联和严重非线性的系统.

分别采用[88,119]和[85,115]的随机数作为输入 q_c 和 q,产生 200 对训练数据. 建模前,先用 10^3 除 T,10^2 除 q_c 和 q 预处理样本. 模型参数 $n_x' = n_y' = 2$,SVM 参数 $C = 10^5$,$\varepsilon = 10^{-5}$ 训练模型[6]. MPC 参数为 $H_p = 3$, $H_u = 2$, $Q(i) = \mathrm{diag}\{3.5, 16\}$, $R(j) = \mathrm{diag}\{0.01, 0.01\}$.

为与 SVMs-NMPC 对比,构造类似图 1 的并行 NNs 多步预测模型. 该模型为具有一个隐层的 BP 神经网络,隐层节点数为 26,函数选取 logsig 和 purelin,用 Levenberg-Marquardt 算法训练. 样本数及产生方法、模型参数以及 MPC 参数均与 SVMs-NMPC 完全相同.

同文献[4]一样,考察设定值跟踪能力和进料成分 C_{af} 在 -4% 阶跃变化时的抗扰动能力. 从图 2 和图 3 可以看出, SVMs-NMPC 能快速且平稳地跟踪设定值变化,而 NNs-NMPC 过渡过程超调和时间较前者要大,且 SVMs-NMPC 的抗扰动能力优于 NNs-NMPC. 比较图 4 和图 5 可知,SVMs-NMPC 的跟踪能力和抗扰动能力明显优于 IM-NMPC,且 NNs-NMPC 的控制性能明显好于 IM-NMPC.

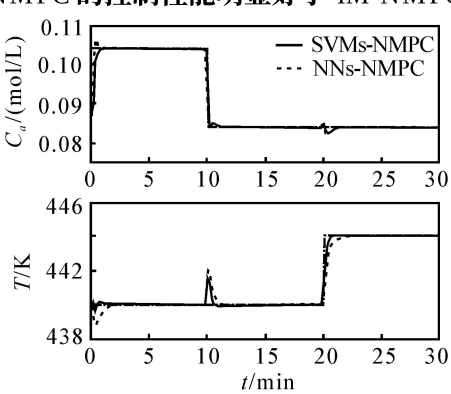

图 2　SVMs-NMPC 与 NNs-NMPC 跟踪性能比较

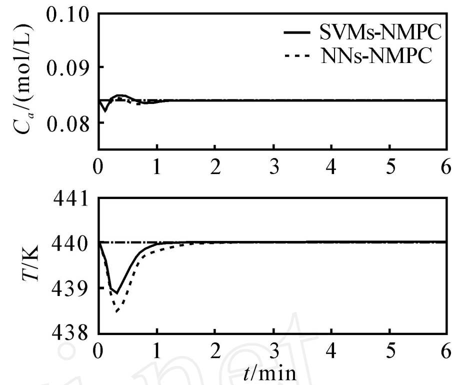

图 3　SVMs-NMPC 与 NNs-NMPC 抗扰动性能比较

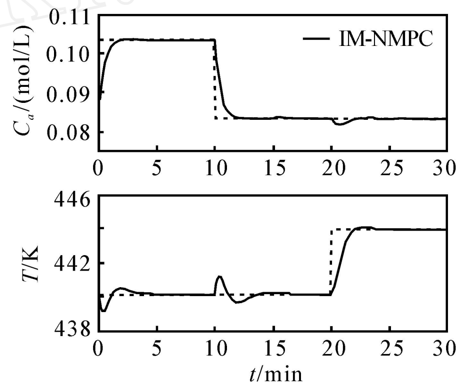

图 4　IM-NMPC 设定值跟踪输出曲线

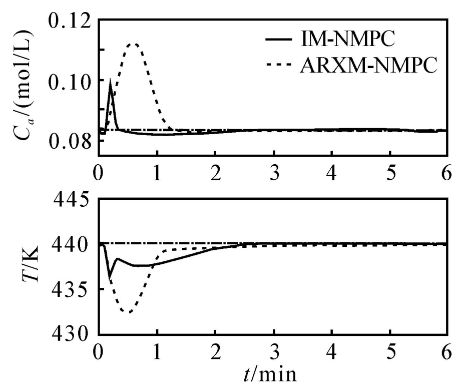

图 5　IM-NMPC 抗扰动输出曲线

参数 H_p 决定 SVM 子模型个数,随着 H_p 的增加,控制性能有所改善,但离线建模工作量加大;而参数 H_u 决定最优控制律的计算复杂性,随着 H_u 的增加,过渡过程性能稍有改进,但在线求解时间加长. $H_p = 3$, $H_u = 2$ 的 CSTR 最优解平均在线计算时间为 0.69 s (PC:1.7 GHz,256 M),能满足采样周期 0.1 min 的要求.

5　结　　论

工业过程大多是非线性多变量系统,因此对这类系统的 NMPC 研究无论从理论还是实践上都非常重要. 本文提出了基于并行二次多项式核函数 SVMs 的多变量系统多步 NMPC 算法. 该算法中基于并行 SVMs 的多变量系统建模方法对多步预测时域是有效的,同时新的反馈校正策略有利于消除

稳态偏差. 通过仿真实验的比较可以看出,该方法具有较好的稳态和暂态控制特性.

参考文献(References)

[1] Dole F J, Ogunnaike B A, Pearson R K. Nonlinear model based control using second-order Volterra models [J]. Automatica, 1996, 31(5): 697-714.

[2] Liu B, Shen Q, Su H Y, et al. A nonlinear predictive control algorithm based on fuzzy online modeling and discrete optimization Systems[C]. Proc IEEE Int Conf on System, Man and Cybernetics. Washington, 2003, 1: 816-821.

[3] Kambhampati C, Mason J D, Warwick K. A stable one-step-ahead predictive control of non-linear systems [J]. Automatica, 2000, 36: 485-495.

[4] 黄道平, 朱学峰, 周其节. 基于一种集成模型的多变量非线性预测控制[J]. 控制理论与应用, 1999, 16(1): 38-42.
(Huang Dao-ping, Zhu Xue-feng, Zhou Qi-jie. Multivariable nonlinear predictive control based on an integrating model [J]. Control Theory and Applications, 1999, 16(1): 38-42.)

[5] Zhong W M, He G L, Pi D Y, et al. SVM with polynomial kernel function based nonlinear model one-step-ahead predictive control [J]. Chinese J of Chemical Engineering, 2005, 13(3): 373-379.

[6] Vapnik V. The nature of statistical learning theory [M]. New York: Springer-Verlag, 1995.

(上接第 921 页)

[11] McMahon D H, Narendran V K. Longitudinal vehicle controller design for IVHS: Theory and experiment [C]. Proc of American Control Conf. Chicago, 1992: 1753-1757.

[12] Aracil J, Heredia G, Ollero A. Global stability analysis of fuzzy path tracking using frequency response [J]. Engineering Applications of Artificial Intelligence, 2000, 13(1): 109-119.

[13] 舒仲周, 张继业, 曹登庆. 运动稳定性[M]. 北京: 中国铁道出版社, 2001.
(Shu Zhong-zhou, Zhang Ji-ye, Cao Deng-qing. Stability of motion [M]. Beijing: China Rail Press, 2001.)

《控制与决策》第四届编委会第一次会议在无锡召开

本刊讯 《控制与决策》第四届编委会第一次会议,于 7 月 4 日在江苏省无锡市召开。《控制与决策》主编王福利教授,副主编冯纯伯院士、程代展研究员,编委王行愚教授、邵世煌教授、顾树生教授、刘建昌教授等 16 位专家参加了会议。徐心和编委受主编的委托主持会议。

王福利主编致欢迎辞。他首先代表张嗣瀛主编,对各位副主编和编委在百忙中前来参加会议表示热烈的欢迎,对各位编委多年来对期刊工作的亲切关怀和大力支持表示衷心的感谢。然后他简要介绍了本刊取得的成绩以及当前面临的主要挑战。他强调:学术期刊最重要的就是要坚持学术水平,多发表高水平的文章,以满足广大读者的需求。他还提出了要办中英文混合版期刊的设想。

《控制与决策》编辑部主任曹洪武同志代表编辑部向编委会汇报了期刊工作。汇报的主要内容有:第四届编委会组建情况,来稿情况和用稿情况,审稿工作及存在的问题,国内外检索情况,影响因子及其他指标,期刊获奖情况,存在的几个问题。

在听取了主编的欢迎辞和编辑部的工作汇报后,各位副主编和编委纷纷发言。大家对期刊工作给予了高度评价,认为本刊在张嗣瀛主编多年的领导下,一直坚持正确的办刊方针,发表了一大批最新研究成果。东北大学和《控制与决策》编辑部做了大量工作,期刊工作取得了很大的成绩。学术期刊必须坚持学术水平,引领学科的发展。可以向一些知名专家主动约稿,请他们撰写带有新方向的高水平的稿件;也要借鉴国外一些期刊的做法,出版某一研究方向的专辑。文章的质量取决于审稿质量,因此需要建立人才库,扩大审稿队伍,加强审稿工作。以后应实行匿名审稿制,也可以考虑编委审稿制。编委会对于期刊的发展具有重要作用,今后要经常召开编委会,并且形成制度。与会的专家表示,今后要积极支持期刊工作,为把《控制与决策》办成国内一流、国际知名的期刊而努力。