

文章编号: 1001-0920(2008)10-1173-05

## 基于熵准则的发酵过程 TSK 模糊建模

谭左平<sup>a,b</sup>, 王士同<sup>a</sup>, 邓赵红<sup>a</sup>, 堵国成<sup>b</sup>

(江南大学 a. 信息工程学院, b. 工业技术教育部重点实验室, 江苏 无锡 214122)

**摘要:** 提出了一种基于熵准则函数的 TSK 模糊系统建模方法. 不同于传统的基于 MSE 经验误差最小的准则函数, 该准则函数能从训练样本的整体分布结构来进行参数学习, 有效地避免了由于过学习而导致泛化能力差的缺点. 将其应用于复杂的发酵过程建模, 结果表明新方法具有良好的预测精度、泛化能力和鲁棒性. 为解决发酵过程建模中试验数据含有噪音, 导致模型预测精度下降的问题提供了一条研究思路.

**关键词:** 相对熵; Parzen 窗法; TSK 模糊系统; 鲁棒性

**中图分类号:** TP274      **文献标识码:** A

## Fermentation process TSK fuzzy modeling based on entropy criteria

TAN Zuoping<sup>a,b</sup>, WANG Shi-tong<sup>a</sup>, DENG Zhao-hong<sup>a</sup>, DU Guo-cheng<sup>b</sup>

(a. School of Information Engineering, b. Key Laboratory of Industrial Biotechnology of Ministry of Education, Jiangnan University, Wuxi 214122, China. Correspondent: TAN Zuoping, E-mail: zuoping\_tantan@126.com)

**Abstract:** A TSK fuzzy modeling approach based on entropy criteria is presented in this paper. It considers the whole distribution structure of the training data set in the parameter learning process, which is different from the traditional MSE-criteria based parameter learning, and effectively avoids the bad generalization caused by over-learning. Then the proposed method is applied to the complex fermentation process modeling, and the results demonstrate that this method has better prediction accuracy, generalization and robustness. Such that it offers a research viewpoint to circumvent the problem of the prediction accuracy deteriorated by noise existing in the corresponding experimental data.

**Key words:** Relative entropy; Parzen window; TSK fuzzy system; Robustness

### 1 引言

随着生物工程技术的迅速发展, 发酵工业的生产规模不断扩大, 生产过程的不断强化, 对自动控制技术的要求也越来越迫切<sup>[1,2]</sup>. 然而, 发酵过程涉及到生命体的生长繁殖过程, 机理十分复杂. 从控制的角度来看, 生物发酵过程往往具有严重的非线性、高度的时变性、高阶多变量以及不确定性的特点. 同时由于生物传感器的缺乏和各参数之间的耦合性, 给发酵过程建模带来了很大的困难. 传统的控制方法致力于建立解析数学模型, 不能胜任发酵过程控制测量技术, 使企业积累的大量原始过程数据得不到很好的应用.

近年来, 将模糊推理与神经网络相结合而产生的模糊神经网络控制系统在发酵领域得到了广泛的应用. 该类系统既具备模糊控制的自然语言处理能

力, 可以方便地将熟练工人的操作经验作为控制规则加入控制器, 同时还具有神经网络的学习能力, 通过对实际数据的训练, 进一步对模糊规则进行修正. 殷铭等<sup>[3]</sup>研究了基于模糊神经网络的 *L*-异亮氨酸发酵过程溶解氧预估控制, 孟华等<sup>[4]</sup>对柠檬酸发酵过程的神经网络模糊控制进行了研究, 冯斌等<sup>[5]</sup>利用 TSK 模糊逻辑系统建立了生化变量预估模型. 但是, 该类技术存在的一个缺点是: 普遍采用传统的基于 MSE 准则的误差函数, 即以样本的实际输出和模糊系统的预测输出的方差为误差准则函数来进行参数学习. 由于 MSE 准则是基于局部逼近原理, 它只考虑了各个样本点处的逼近情况, 要求所有样本点的经验误差达到最小, 而没有考虑样本之间的空间, 这使得在某些情况下出现过学习现象而降低了模型的泛化能力和鲁棒性.

收稿日期: 2007-08-10; 修回日期: 2007-12-08.

基金项目: 国家 863 计划项目(2006AA10Z313).

作者简介: 谭左平(1981—), 女, 湖北宜昌人, 博士生, 从事发酵控制、模糊系统等研究; 王士同(1964—), 男, 江苏扬州人, 教授, 博士生导师, 从事人工智能、模式识别等研究.

本文针对该问题,借助信息论中关于熵的概念,从概率密度的角度出发<sup>[6]</sup>,利用判别熵构造出一个误差准则函数,并将其应用于乳酸杆菌发酵生成胞外多糖(EPS)的模糊控制系统.同传统的基于MSE准则的误差函数相比,本文提出的基于熵准则的误差函数从所有样本整体出发,暗含了样本潜在的分布结构,因此能够从全局的角度对模糊系统的参数进行学习,从而有效地增强了学习得到的模型的泛化能力和鲁棒性.实验结果证实了上述优点.

## 2 传统的TSK模糊系统及其参数学习

### 2.1 TSK模糊系统规则

TSK模糊系统<sup>[7,8]</sup>是非线性复杂系统建模中的一种典型的模糊模型,其模糊规则可表示如下:

$$R_i: \text{if } x_1 \text{ is } A_{i1} \text{ and } x_2 \text{ is } A_{i2} \dots \text{and } x_d \text{ is } A_{id}, \\ \text{then } y^i = p_{i0} + p_{i1}x_1 + \dots + p_{id}x_d. \quad (1)$$

其中: $R_i$ 代表第*i*条模糊规则( $i = 1, 2, \dots, M$ ), $M$ 是模糊规则数; $x_j$ 是第*j*个输入变量( $j = 1, 2, \dots, d$ ), $d$ 是输入变量个数; $A_{ij}$ 是一个模糊集合,其隶属度函数定义为 $A_{ij}(x_j) = e^{-(x_j - a_{ij})^2/b_{ij}^2}$ ;  $p_{ij}$ 是第*i*条模糊规则结论部分的线性多项式函数中变量 $x_j$ 项的系数; $y^i$ 是第*i*条模糊规则的输出.由式(1)可见,TSK模糊系统规则的前提部分是模糊的,但结论部分是确定的,即输出为各输入变量的线性组合.对于一个实数值输入向量 $x = (x_1, x_2, \dots, x_d)$ 而言,TSK模糊系统的输出 $y$ 等于 $y^i$ 的加权平均,即

$$y = \left( \sum_{i=1}^M w^i y^i \right) / \sum_{i=1}^M w^i, \quad (2)$$

其中

$$w^i = \prod_{j=1}^d A_{ij}(x_j).$$

### 2.2 基于MSE准则的TSK参数学习

传统的模糊系统建模过程中广泛采用样本的实际输出和模糊系统的预测输出的平方差为误差准则函数,即MSE准则函数为

$$E_i = \frac{1}{2N} \sum_{i=1}^N (y_i - y_{di})^2. \quad (3)$$

从式(3)可以看出,传统的建模过程是一个局部逼近过程,即点点逼近.它只考虑了各个样本点处的逼近情况,而忽略了样本之间的空间.因为该准则要求所有样本点的整体均方误差达到最小值,所以学习所得的网络的泛化能力和鲁棒性得不到保证,可能会出现过拟合问题.特别是当试验数据存在噪音的情况下,学习得到的模型性能会恶化.

## 3 基于熵准则的TSK建模

针对前面讨论的传统的TSK模型面临的问题,

本文从另一个角度进行探讨,即从熵的角度提出一种TSK模糊系统建模方法,下面给出具体的描述.

### 3.1 相对熵和判别熵

在信息论中,用“熵”作为不确定性的一种度量的表达式,它是概率密度分布的函数.这样一个概念也可以用来作为某个概率密度分布 $f_1(x_i)$ 偏离给定的标准分布 $f_2(x_i)$ 的程度的度量,此时称之为相对熵,即

$$V(f_1, f_2) = \int f_1(x_i) \log[f_1(x_i)/f_2(x_i)] dx_i. \quad (4)$$

由式(4)可得:相对熵越小,这两类概率密度分布的差别就越大,反之,差别就越小,当两类概率分布完全相同时,相对熵达到最大值(等于零).因此可以用如下的判别熵 $W(f_1, f_2)$ 来表征两类分布 $f_1(x_i)$ 和 $f_2(x_i)$ 的差别大小:

$$W(f_1, f_2) = V(f_1, f_2) + V(f_2, f_1) = \int f_1(x_i) \log[f_1(x_i)/f_2(x_i)] dx_i + \int f_2(x_i) \log[f_2(x_i)/f_1(x_i)] dx_i = \int f_1(x_i) \log[f_1(x_i)] dx_i + \int f_2(x_i) \log[f_2(x_i)] dx_i - \int f_1(x_i) \log[f_2(x_i)] dx_i - \int f_2(x_i) \log[f_1(x_i)] dx_i. \quad (5)$$

### 3.2 基于相对熵的准则函数

给定训练样本集 $\{x_i, y_{di}\}$ .其中: $x_i \in R^d, y_{di} \in R, i = 1, 2, \dots, N$ .对于TSK模糊系统,可以构造出2个新的数据集,即模糊系统样本输入 $x_i$ 与样本输出 $y_{di}$ 构成的向量集合 $Z_i \in R^d$ (其中 $d = d + 1$ )和模糊系统样本输入 $x_i$ 与系统预测输出 $y_i$ 构成的向量集合 $Z_i \in R^d$ ,分别为

$$S_1 = \{Z_i \mid Z_i = (x_i, y_{di})\},$$

$$S_2 = \{Z_i \mid Z_i = (x_i, y_i)\}.$$

根据统计学中的相关原理,给定样本集合 $\{x_i\}, x_i \in R^d$ ,利用Parzen窗法<sup>[6]</sup>可以估计出其样本空间中任意一点的概率密度函数

$$f(x, ) = \frac{1}{N} \sum_{i=1}^N \frac{1}{(\sqrt{2})^d} e^{-\frac{x \cdot x_i}{2^2}}, \quad (6)$$

其中 $\sqrt{2}$ 表示窗口的宽度.不同的数据集对应于不同的 $\sqrt{2}$ 值,而且 $\sqrt{2}$ 的大小直接影响着概率密度估计的效果.对于该参数,采用基于相似度的交叉验证法来确定 $\sqrt{2}$ 的值<sup>[9]</sup>.

根据式(6),对于数据集 $S_1$ 和 $S_2$ ,可以分别得出概率密度函数 $f_1(z, )$ 和 $f_2(z, )$ 为

$$f_1(z, ) = \frac{1}{N} \sum_{i=1}^N \frac{1}{(\sqrt{2})^d} e^{-\frac{z \cdot z_i}{2^2}}, \quad (7)$$

$$f_2(z, ) = \frac{1}{N} \prod_{i=1}^N (\sqrt{2})^{-d} e^{-\frac{z-z_i}{2^2}}, \quad (8)$$

令  $G(z - z, ^2) = e^{-\frac{z-z_i}{2^2}}$ , 则式(7)和(8)可转化为

$$f_1(z, ) = \frac{(\sqrt{2})^{-d}}{N} \prod_{t_1=1}^N G(z - z, ^2), \quad (9)$$

$$f_2(z, ) = \frac{(\sqrt{2})^{-d}}{N} \prod_{t_2=1}^N G(z - z, ^2). \quad (10)$$

利用 3.1 节中提到的相对熵的性质可知, 相对熵越大, 两个概率密度分布的差别就越小, 当相对熵达到最大值时, 两个概率密度分布完全相同, 即  $f_2(z, )$  和  $f_1(z, )$  同分布. 换言之, 系统预测输出  $y_i$  接近样本输出  $y_{di}$ . 为此, 定义一个新的目标函数如下:

$$\begin{aligned} E_2 = & -W(f_1, f_2) = \\ & -[V(f_1, f_2) + V(f_2, f_1)] = \\ & \int f_1(z) \log[f_1(z)/f_2(z)] dz + \\ & \int f_2(z) \log[f_2(z)/f_1(z)] dz = \\ & \int \{f_1(z) [\log f_1(z) - \log f_2(z)] + \\ & f_2(z) [\log f_2(z) - \log f_1(z)]\} dz. \quad (11) \end{aligned}$$

根据 Taylor 级数展开,  $\log f(z)$  可以近似为

$$\log f(z) = \log[1 + (f(z) - 1)] \approx f(z) - 1. \quad (12)$$

将式(12)代入(11)化简得

$$E_2 = \int [f_1^2(z) + f_2^2(z) - 2f_1(z)f_2(z)] dz. \quad (13)$$

在文献[10]中, Erhan 等详细推导了如下结论:

$$\int f_1^2(z) dz = \frac{(\sqrt{2} \sqrt{2})^{-d}}{N^2} \prod_{t_1=1, t_2=1}^N G(z_{t_1} - z_{t_2}, 2^2), \quad (14)$$

$$\int f_2^2(z) dz = \frac{(\sqrt{2} \sqrt{2})^{-d}}{N^2} \prod_{t_1=1, t_2=1}^N G(z_{t_1} - z_{t_2}, 2^2), \quad (15)$$

$$\int f_1(z)f_2(z) dz = \frac{(\sqrt{2} \sqrt{2})^{-d}}{N^2} \prod_{t_1=1, t_2=1}^N G(z_{t_1} - z_{t_2}, 2^2). \quad (16)$$

将式(14)~(16)代入(13), 化简可得

$$E_2 = \frac{(\sqrt{2} \sqrt{2})^{-d}}{N^2} \int \left[ \prod_{t_1=1, t_2=1}^N G(z_{t_1} - z_{t_2}, 2^2) + \right.$$

$$\left. - 2 \prod_{t_1=1, t_2=1}^N G(z_{t_1} - z_{t_2}, 2^2) \right]. \quad (17)$$

这样便构造了一个基于概率密度函数和熵准则的准则函数, 该准则函数能暗含样本集的潜在结构, 从而有效地克服了传统的 MSE 准则函数只能从局部进行学习的缺陷. 下一阶段将给出基于新的准则函数的 TSK 模糊系统的参数学习规则.

### 3.3 基于相对熵准则的 TSK 参数学习

利用提出的熵准则函数(如式(17)所示)和梯度学习算法, 容易得到如下 TSK 模型的参数学习规则:

$$p_j^i(t+1) = p_j^i(t) - \eta \frac{\partial E_2}{\partial p_j^i}, \quad (18)$$

$$a_j^i(t+1) = a_j^i(t) - \eta \frac{\partial E_2}{\partial a_j^i}, \quad (19)$$

$$b_j^i(t+1) = b_j^i(t) - \eta \frac{\partial E_2}{\partial b_j^i}. \quad (20)$$

其中: 训练次数  $t = 0, 1, \dots, n$  和  $\eta$  是学习率;  $i = 1, 2, \dots, M$ ;  $j = 1, 2, \dots, d$ .

## 4 实验结果

下面对提出的方法在乳酸杆菌发酵生成胞外多糖(EPS)的模糊控制系统中的性能进行探讨.

### 4.1 乳酸杆菌胞外多糖的简介

胞外多糖(EPS)是两种多糖的总称. 由一种单糖组成的乳酸杆菌胞外多糖叫同多糖, 由几种单糖组成的叫杂多糖. 因为乳酸菌是益生菌, 乳酸杆菌胞外多糖可以直接应用于食品中, 同时胞外多糖还具有抗肿瘤、抗溃疡和降低胆固醇等活性. 另外, 最新研究表明, 乳酸杆菌胞外多糖对人体免疫系统有调节作用和宿主识别作用, 因此具有广泛的研究和应用价值.

### 4.2 预测误差指数 J

为了方便比较, 采用如下误差指数  $J$  来评价模型的性能<sup>[11,12]</sup>:

$$J = \sqrt{\frac{\sum_{l=1}^N (y_l - y_l^d)^2}{\sum_{l=1}^N (y_l^d - \bar{y})^2}}. \quad (21)$$

其中:  $\bar{y} = \frac{1}{N} \sum_{l=1}^N y_l^d$ ,  $N$  为样本总数,  $y_l^d$  为第  $l$  个样本值的期望输出,  $y_l$  为实际输出.  $J$  值越小, 意味着建模的精度越高.

### 4.3 仿真实验

本文采用乳酸杆菌发酵产生胞外多糖的实验数据<sup>[13]</sup>, 如表 1 所示. 模糊系统的输入为表中对应的 4 个因素水平值, 输出为表中胞外多糖的均值, 1~44 组数据作为训练样本, 45~54 组用于测试. 分别采

表1 乳酸杆菌发酵实验数据

	Factors and levels				EPS		Factors and levels				EPS
	L	T	C	I			L	T	C	I	
1	8	0	2	1.5	2.29 ±0.41	28	20	0.3	5	1	1.90 ±0.44
2	8	0.2	8	3.5	3.43 ±0.12	29	8	0.2	4	3.5	2.68 ±0.42
3	25	0	4	1.5	5.16 ±0.73	30	8	0	4	2	2.65 ±0.45
4	8	0.2	2	2	2.38 ±0.62	31	8	0.2	2	1.5	2.51 ±0.66
5	25	0.2	2	2	4.51 ±0.37	32	4	0.2	8	2	1.99 ±0.07
6	25	0.2	8	2	5.32 ±0.12	33	25	0	4	3.5	5.04 ±0.16
7	20	0.2	8	1	1.64 ±0.18	34	40	0.2	4	1	1.88 ±0.05
8	4	0.2	4	1.5	1.54 ±0.04	35	2	0.2	4	1	0.65 ±0.46
9	25	0.2	4	2	5.20 ±0.24	36	8	0.2	8	2	3.55 ±0.40
10	25	0	8	1.5	5.66 ±0.76	37	8	0.2	4	1	1.20 ±0.05
11	8	0	4	1.5	2.80 ±0.01	38	20	0.2	4	1	1.70 ±0.18
12	20	0.1	5	1	1.80 ±0.50	39	25	0	2	3.5	4.61 ±0.73
13	10	0.2	4	1	1.35 ±0.64	40	4	0	8	1.5	2.26 ±0.48
14	4	0	4	1.5	1.43 ±0.15	41	4	0.2	8	3.5	2.17 ±0.39
15	25	0.2	4	1.5	5.22 ±0.57	42	20	0.2	1	1	0.80 ±0.69
16	4	0	2	2	0.98 ±0.58	43	4	0	2	3.5	1.02 ±0.34
17	8	0.2	4	1.5	2.91 ±0.32	44	25	0	2	2	4.90 ±0.57
18	8	0.2	8	1.5	3.79 ±0.53	45	4	0.2	2	3.5	1.11 ±0.21
19	4	0.2	2	1.5	1.08 ±0.42	46	20	0.2	5	1	1.95 ±0.26
20	4	0.2	4	1	0.80 ±0.51	47	20	0.2	3	1	1.40 ±0.13
21	25	0	4	2	5.40 ±0.12	48	4	0.2	8	1.5	1.98 ±0.79
22	4	0	4	2	1.59 ±0.34	49	4	0.2	4	2	1.60 ±0.73
23	25	0	8	3.5	5.13 ±0.30	50	4	0.2	4	3.5	2.53 ±0.28
24	8	0	2	2	2.59 ±0.59	51	25	0.2	2	3.5	5.04 ±0.69
25	8	0	4	3.5	2.87 ±0.47	52	4	0	8	3.5	2.25 ±0.12
26	8	0	8	3.5	3.78 ±0.52	53	20	0.4	5	1	1.86 ±0.26
27	4	0	8	2	2.21 ±0.71	54	25	0	8	2	5.64 ±0.66

注: L表示 lactose/(g/l), T表示 triammonium citrate/(g/l), C表示 casein hydrolysate/(g/l), I表示 inoculum size/(vol %).

用如式(3)和(17)所示的2种误差准则函数进行训练,考察2种方法的预测精度以及鲁棒性.

对于模糊系统发酵过程建模问题而言,当输入数据的维数等于4时,一般情况下,模糊规则数为7~11个,对许多建模问题是比较合适的原则.本研究中,当规则数分别为7,8,9,10,11时,做了相应的仿真实验,根据选用不同规则数得到的实验结果,能得到相似的结论.为了节省篇幅,文中仅给出模糊规则数为8时的实验结果和实验分析.为了在公平的前提下比较2种建模方法,设定相同的标准,即当梯度小于 $10^{-4}$ 时,停止迭代.分别用基于MSE准则和熵准则的发酵数据TSK模糊建模效果如表2所示.

表2 发酵数据TSK模糊建模效果

准则函数	训练样本数	测试样本数	TSK规则数	训练误差指数J	测试误差指数J	窗口宽度
MSE准则	44	10	8	0.3566	0.8810	-
熵准则	44	10	8	0.4962	0.6889	0.7

从表2中可以看出,当梯度小于 $10^{-4}$ 时,本文提出的基于熵准则的方法的训练误差指数J为0.4962,测试误差指数J为0.6889;而基于传统的MSE准则的方法,其训练误差指数J为0.3566,但

是测试误差指数J却只达到了0.8810.这就说明,在设定了相同标准的情况下,基于MSE准则的方法发生过拟合的风险较大.所以与本文提出的方法相比,基于MSE准则的方法泛化能力差,容易产生过拟合现象.故文中基于熵准则的方法能够更快速、更准确地预测出乳酸杆菌的发酵过程.

由于实际的发酵过程非常复杂,试验数据往往不可避免地带有-定量的噪音,在进行发酵建模过程中,模型的鲁棒性是一个非常重要的指标.为了进一步说明该方法良好的鲁棒性,下面对实验数据加入噪音.考虑到在实际的发酵过程中,在实验操作正确的前提下,数据中的噪音量不会超过20%.为此,在所加噪音量介于0~20%的前提下,累计做了16组实验,每次所加噪音量以及相应的测试误差指数J的值如表3所示.

显然,从表3可以得出结论:文中所提出的基于熵准则的方法,其预测精度明显高于传统的基于MSE准则的方法,而且随着实验数据中噪音量的增加,新方法所对应的测试误差指数值的变化相对比较缓慢,故基于熵准则的方法具有良好的鲁棒性.

为了更直观地显示出本文提出方法良好的鲁棒

表 3 对加入噪音的发酵数据的模糊建模效果

	噪音量	MSE 准则 测试误差 指数 $J$	熵准则 测试误差 指数 $J$
1	0.0	0.8810	0.6889
2	0.01	0.9521	0.7246
3	0.02	1.0852	0.7446
4	0.03	1.1292	0.7438
5	0.04	1.1616	0.7641
6	0.05	1.1830	0.7933
7	0.06	1.2195	0.8051
8	0.07	1.1960	0.8063
9	0.08	1.2237	0.8170
10	0.09	1.2291	0.8068
11	0.10	1.2531	0.8124
12	0.12	1.2330	0.8235
13	0.14	1.2689	0.8201
14	0.16	1.2680	0.8390
15	0.18	1.2798	0.8771
16	0.20	1.3141	0.8733

性,两种方法的效果对比如图 1 所示.

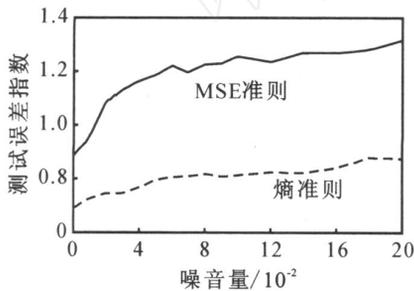


图 1 两种方法的建模效果对比

从图 1 中可以直观地看出:基于熵准则方法的误差指数曲线始终位于基于 MSE 准则方法的误差指数曲线的下部,而且相对比较平稳,即本文提出方法具有良好的预测精度、泛化能力和鲁棒性.

如上所述,实验中模糊系统的输出均采用 EPS 的均值.但从表 1 所列出的试验数据可以看出,因为变量 EPS 的标准差比较大,所以必须从统计学的角度对 2 种建模方法的性能加以分析.下面保持模糊系统的样本输入不变,对每个样本输出数据(EPS)分别加入一个随机产生的高斯噪音,该噪音的均值为零,标准差为各试验数据中对应的标准差,如此循环 50 次,最后计算 2 种建模方法所对应的测试误差指数  $J$  的均值和标准差,实验结果如表 4 所示.

表 4 两种建模方法的统计分析结果

方法	模糊规则数	测试误差指数 $J$
MSE 准则	8	1.1197 ±0.1807
熵准则	8	0.9240 ±0.1210

从表 4 可以看出,基于熵准则的方法的预测误差指数的均值和标准差都明显低于传统的 MSE 准

则的方法,这就再次验证了本文所提出的方法具有良好的预测能力、泛化能力以及鲁棒性.

### 5 结 论

本文从另一个角度提出了基于熵准则的 TSK 模糊系统建模方法.它能从全局出发,在参数的学习阶段考虑了所有样本的整体分布结构.将其运用到乳酸杆菌发酵生成胞外多糖(EPS)的实验中,结果证明本文方法具有较高的预测精度、泛化能力和良好的鲁棒性.这为实际发酵生产中,在实验数据由于客观条件的限制往往含有一定噪音的情况下的建模问题,提供了一个崭新的研究思路,具有一定的研究价值.

### 参考文献(References)

[1] 杜锋,雷鸣,刘全. 发酵过程的先进控制[J]. 信息与控制, 2004, 33(3): 314-317.  
(Du F, Lei M, Liu Q. Advanced control in fermentation process[J]. Information and Control, 2004, 33(3): 314-317.)

[2] 高学金,王普,孙崇正,等. 微生物发酵过程建模与优化控制[J]. 控制工程, 2006, 13(2): 152-153.  
(Gao X J, Wang P, Sun C Z, et al. Modeling and optimization control for the microbial fermentation process[J]. Control Engineering of China, 2006, 13(2): 152-153.)

[3] 殷铭,张兴华,戴先中. 基于模糊神经网络的发酵过程溶解氧预估控制[J]. 控制与决策, 2000, 15(5): 523-526.  
(Yin M, Zhang X H, Dai X Z. Dissolved oxygen predictive control based on fuzzy neural networks for fermentation process[J]. Control and Decision, 2000, 15(5): 523-526.)

[4] 孟华,付小美,曹桂萍. 柠檬酸发酵过程的神经网络模糊控制[J]. 河北工业科技, 1999, 16(3): 53-55.  
(Meng H, Fu X M, Cao G P. Neural network fuzzy control of citric acid fermentation process[J]. Hebei J of Industrial Science and Technology, 1999, 16(3): 53-55.)

[5] 冯斌,须文波. 基于 TSK 模糊系统的生化变量预估模型[J]. 计算机与应用化学, 2006, 23(4): 343-346.  
(Feng B, Xu W B. Biochemical variable estimation model based on TSK fuzzy system[J]. Computers and Applied Chemistry, 2006, 23(4): 343-346.)

[6] 边肇祺,张学工,张长水,等. 模式识别[M]. 北京: 清华大学出版社, 1999.  
(Bian Z Q, Zhang X G, Zhang C S, et al, Pattern recognition[M]. Beijing: Press of Tsinghua University, 1999.)

(下转第 1181 页)

$$K_2 = KB = \begin{bmatrix} - 3.3069 & 3.0783 \\ - 1.6861 & - 0.6931 \end{bmatrix},$$

$$K_3 = KAB = \begin{bmatrix} - 1.8879 & 10.1436 \\ - 9.0157 & 6.7103 \end{bmatrix}.$$

则由定理 2 的证明过程得到递推滞后反馈控制器为

$$z(k+1) = (A - GC)z(k) + Gy_d(k) + Bu(k-2),$$

$$u(k) = K_1 z(k) + K_2 u(k-1) + K_3 u(k-2).$$

设定初始值

$$x(-2) = [5 \ 2 \ -6 \ 0]^T,$$

$$x(-1) = [-5 \ 3 \ 5 \ 4]^T,$$

$$x(0) = [5 \ 2 \ 0 \ 5]^T, \quad z(0) = [1 \ 2 \ -1 \ -2]^T,$$

$$u(-1) = [3 \ 4]^T, \quad u(-2) = [-3 \ 6]^T.$$

对控制系统作数值仿真,由图 1 可见闭环系统是渐近稳定的,其中 4 条曲线分别表示  $x$  的 4 个状态分量.

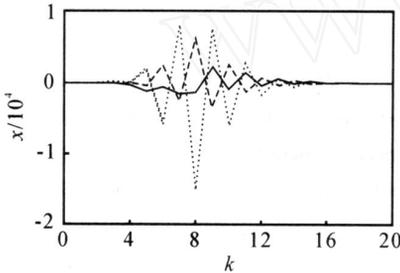


图 1 状态  $x$  的 4 个分量的受控行为

### 4 结 论

本文解决了带输出传输滞后的线性离散系统的  $n$  阶状态观测器设计问题,设计了基于观测器的输出动态反馈控制器,证明了闭环系统满足极点分离

原理.数值仿真例子验证了该方法的有效性.

### 参考文献(References)

[1] 程兆林,马树萍.线性系统理论[M].北京:科学出版社,2006.  
(Cheng Z L, Ma S P. Linear system theory [M]. Beijing: Publication of Science, 2006.)

[2] Lian F L, Moyne J, Tilbury D. Analysis and modeling of networked control systems: MIMO case with multiple time delays [C]. Proc of the American Control Conf. Arlington, 2001: 4306-4312.

[3] Yong J. Stabilization of discrete-time linear systems with a time delay in the feedback loop [J]. Int J Control, 1988, 48(4): 1475-1485.

[4] Konishi K, Kokame H. Observer-based delayed feedback control for discrete-time chaotic systems [J]. Physics Letters A, 1998, 248(5/6): 359-368.

[5] Yamamoto S, Hino T, Ushio T. Dynamic delayed feedback controller for chaotic discrete-time systems [J]. IEEE Trans on Circuits and Systems — Fundamental and Applications, 2001, 48(6): 785-789.

[6] Yamamoto S, Hino T, Ushio T. Recursive delayed feedback control for chaotic discrete-time systems [C]. Proc of the 40th IEEE Conf on Decision and Control. Orlando, 2001: 2187-2192.

[7] Zhu J, Tian Y P. Nonlinear recursive delayed feedback control for chaotic discrete-time systems [J]. Physics Letters, 2003, 310(4): 295-300.

[8] Pyragas K. Continuous control of chaos by self-controlling feedback [J]. Physics Letters A, 1992, 170(6): 421-428.

(上接第 1177 页)

[7] 王士同.神经模糊系统及其应用[M].北京:北京航空航天大学出版社,1998.  
(Wang S T. Neural-fuzzy system and their application [M]. Beijing: Publishing House of Beijing Aeronautical University, 1998.)

[8] 王士同.模糊系统、模糊神经网络及应用程序设计[M].上海:上海科学技术文献出版社,1998.  
(Wang S T. Fuzzy system, fuzzy neural networks and their programming [M]. Shanghai: Press of Shanghai Science and Technology, 1998.)

[9] Grolami M, He Chao. Probability density estimation from optimally condensed data samples [J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 2003, 25(10): 1253-1264.

[10] Erhan G, Jose C P. Information theoretic clustering

[J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 2002, 24(2): 158-171.

[11] Chung F L, Wang S T, Deng Z H, et al. CATSMLP: Towards a robust and interpretable multilayer perceptron with sigmoid activation functions [J]. IEEE Trans on Systems, Man and Cybernetics, 2006, 36(6): 1319-1331.

[12] Jang J S R, Sun C T, Mizutani E. Neuro-fuzzy and soft computing [M]. New Jersey: Prentice-Hall, 1997.

[13] Desai K M, Kolkar S K A, Badhe Y P, et al. Optimization of fermentation media for exopolysaccharide production from Lactobacillus plantarum using artificial intelligence based techniques [J]. Process Biochemistry, 2006, 41(8): 1842-1848.