

## 多阶段逆模型方法及在胶液生成过程中的应用

彭彦卿<sup>1,2</sup>, 罗 键<sup>2</sup>, 葛晓宏<sup>3</sup>, 庄进发<sup>2</sup>, 邓兴旺<sup>4</sup>, 苏志伟<sup>4</sup>

(1. 厦门理工学院电子与电气工程系, 厦门 361024; 2. 厦门大学自动化系, 厦门 361005;

3. 厦门理工学院科技处, 厦门 361024; 4. 厦门星鲨制药有限公司, 厦门 361026)



**摘要:** 针对一类串联型工业大系统, 提出了多阶段逆模型建模方法: 将串联大系统分为若干个阶段, 以产品质量指标作为过程设计的起点, 用逆向推理的方法, 建立各个阶段的逆模型; 根据产品质量指标的要求, 直接求出各个阶段的控制变量设定值。将该方法应用于胶液生成过程的软测量建模, 采用多阶段建模方法和整体建模方法分别建立了基于 BP 神经网络的胶液生成过程逆模型, 并从误差平方和 MSE 和命中率等方面对两种建模方法的建模精度进行了比较。结果表明, 多阶段建模方法可以获得更高的建模精度; 同时, 具有更大的灵活性; 而且逆模型方法可以根据质量指标求出控制变量设定值, 更便于实际应用。

**关键词:** 多阶段建模; 逆模型; 软测量; 胶液生成过程; BP 神经网络

**中图分类号:** TP391.9      **文献标识码:** A      **文章编号:** 1004-731X (2009) 04-1178-04

Multistage Inverse Modeling Method and Its Application  
in Gelatin Solution Production ProcessPENG Yan-qing<sup>1,2</sup>, LUO Jian<sup>2</sup>, GE Xiao-hong<sup>3</sup>, ZHUANG Jin-fa<sup>2</sup>, DENG Xing-wang<sup>4</sup>, SU Zhi-wei<sup>4</sup>

(1. Department of Electronic and Electrical Engineering, Xiamen University of Technology, Xiamen 361024, China;

2. Department of Automation, Xiamen University, Xiamen 361005, China;

3. Department of Technology and Science, Xiamen University of Technology, Xiamen 361024, China;

4. Xiamen Xingsha Pharmaceutical Co., Ltd., Xiamen 361024, China)

**Abstract:** Aiming at a class of serially connected industrial system, a novel multistage inverse modeling method was presented. The large-scale system is divided into several stages. Using specified product qualities as a starting point for process design. By backward reasoning the required process conditions and the control variable set points of all stages for processing system were found. The inverse models of gelatin solution production process were established based on the BP neural network by using multistage modeling method and whole stage modeling method, and modeling accuracy comparison were made from error and hit rates. The simulation results indicate the model based on the proposed method has smaller error and higher hit rates. Meanwhile, the break down of the sub models increases the flexibility of model development and reduces the effort to change the model when the sub models change. And the required process conditions and the control variable set points of all stages for processing system were found according to specified product qualities. Thus, it is easy to be really applied. This method has been successfully applied on improving the gelatin solution production process and product quality control.

**Key words:** multistage inverse modeling; inverse modeling; soft sensor; gelatin solution production process; BP neural network

## 引 言

软胶囊是鱼肝油生产行业最主要的产品系列之一, 通过专用设备将药液包裹在胶皮内形成; 明胶溶液是影响软胶囊产品质量最重要的因素, 因为胶液生成过程要经过若干环节, 期间会发生复杂的物理和化学变化, 具有明显的非线性, 中间控制变量关系复杂, 是一个十分复杂的工业过程。传统的系统建模方法是利用人们对物理过程的认识, 通过机理分析建立系统的模型结构, 然后再利用观测到的数据来估计模型的参数。对于线性系统或本质线性系统, 这种方法是比较有效的。但是对于复杂非线性系统, 采用这种传统的建模方

法很难建立准确的系统模型, 因此需要采取基于数据驱动的建模方法。

在对氧乐果间歇生产过程<sup>[1]</sup>, 镍闪速炉熔炼过程<sup>[2]</sup>, 直接甲醇燃料电池<sup>[3]</sup>进行建模的过程中, 人们采用了基于神经网络的建模方法; 在对青霉素发酵过程建模的过程中, 采用了基于支持向量机的数据驱动建模方法<sup>[4]</sup>, 文献[5-9]也采用了基于数据驱动的建模方法, 取得了较好的建模效果。

万百五教授领导的课题组对工业生产的产品质量模型和质量控制模型进行了研究<sup>[2]</sup>, 提出和开发了产品逆质量模型和动、稳态质量控制模型; 但是建模时均是把所有阶段过程视为一个整体过程, 而大型加工生产线往往是一个串联型工业大系统, 因此在建模的精度和效率方面会存在一定的问题; 由于整体建模方法输入输出变量的维数增加, 建模精度会降低, 训练难度也会增大, 甚至造成系统不能收敛; 而且如果整个系统中有一个环节发生变化, 需要对整个系统重新进行模型, 使得模型的柔性欠佳。

**收稿日期:** 2008-10-17      **修回日期:** 2008-12-17

**基金项目:** 厦门市科技计划项目(3502Z20083028); 国家自然科学基金项目(50843059); 福建省教育厅科技项目(JA08218)。

**作者简介:** 彭彦卿(1966-), 女, 河北晋州人, 副教授, 高级工程师, 博士生, 研究方向为智能控制、过程控制和复杂工业生产系统的建模、控制与优化等; 罗键(1954-), 男, 福建连城人, 教授, 博导, 研究方向为现代集成制造系统、复杂系统建模、控制与优化等。

基于以上分析, 本文提出了一种多阶段逆模型建模方法, 并采用基于 BP 神经网络的数据驱动方法加以实现。面向最终产品质量的逆模型方法, 以产品质量指标作为过程设计的起点, 用逆向推理的方法, 直接求出各个阶段的控制变量设定值, 更便于实际应用; 多阶段建模方法充分考虑了串联型工业大系统的特点, 更符合生产工艺的真实情况, 可以有效地提高建模的质量; 而且, 多阶段建模具有更大的灵活性, 如果系统中某个环节发生变化, 那么只需要对该环节进行建模即可, 不需要对整个系统重新建模, 增加了模型的灵活性; 同时, 多阶段建模降低了输入输出变量维数, 可以提高模型的收敛速度和建模精度。将本文中提出的方法应用于溶胶系统的软测量建模, 针对生产工艺的要求, 采用多阶段建模方法和整体建模方法分别建立了基于 BP 神经网络的胶液生成过程逆模型, 实验结果表明多阶段建模方法比整体建模可以获得更高的建模精度。

### 1 系统数学模型描述

一个由  $N$  个子系统组成的工业大系统如图 1 所示, 该系统 (包括它的直接控制器) 可用关系式表示为

$$\begin{aligned} y_i &= F_i^*(c_i, u_i), \\ u_i &= y_{i-1}, \quad i \in \overline{1, N} \end{aligned} \quad (1)$$

式中  $y_i, u_i, c_i$  分别是第  $i$  子系统的输出、关联输入和控制变量;  $F_i^*: C_i \times U_i \rightarrow Y_i$  为第  $i$  子系统的输入-输出映射,  $C_i, U_i$  和  $Y_i$  为有限维的欧式空间。




图 1 工业大系统示意图

则其相应的逆模型则为系统的逆过程, 如图 2 所示。其映射关系为  $K_i^*: Y_i \rightarrow C_i \times U_i, i \in \overline{2, N}$ 。

通常  $u_1$  是已知的参数变量, 如原材料的性能指标是给定的, 而且是可以测出的, 因此子系统 1 的逆模型其映射关系为  $K_1^*: Y_1 \times U_1 \rightarrow C_1$ 。




图 2 多阶段逆模型示意图

一个三层 BP 神经网络可以任意逼近任一非线性映射, 只要由足够的隐层上的隐节点个数。一个三层 BP 神经网络可由图 3 表示。

实践证明, 在给出的输入、输出变量的小范围内逆模型是可能存在的<sup>[2]</sup>。现从理论上进一步分析该模型的可逆条件: 设第  $q$  层 ( $q \in \overline{1, 3}$ ) 的神经元个数为  $n_q$ , 第一层的第  $i$  神经元到第二层的第  $j$  神经元的联接权系数为  $\omega_{ij}$ , 第二层的




图 3 三层神经网络结构图

第  $j$  神经元到输出层的连接权系数为  $\omega_j$ , 则神经网络模型的单维 (第三层) 输出  $y$  为

$$y = F\left(\sum_{j=0}^{n_2} \omega_j s_j\right) \quad (2)$$

BP 神经网络模型的输出  $y$  对  $x_i$  求导数, 由连续函数的求导法则可知

$$\begin{aligned} \frac{\partial y}{\partial x_i} &= F'\left(\sum_{j=0}^{n_2} \omega_j s_j\right) \frac{\partial}{\partial x_i} \left(\sum_{j=0}^{n_2} \omega_j s_j\right) \\ &= F'\left(\sum_{j=0}^{n_2} \omega_j s_j\right) \left(\sum_{j=0}^{n_2} \omega_j \frac{\partial s_j}{\partial x_i}\right) \end{aligned} \quad (3)$$

$$\frac{\partial s_j}{\partial x_i} = F'\left(\sum_{k=0}^{n_1} \omega_{kj} x_k\right) \omega_{ij}$$

$$F'(x) = \frac{1}{1 + e^{-\mu x}} = \mu F(x)(1 - F(x))$$

将上式代入式(3), 得

$$\begin{aligned} \frac{\partial y}{\partial x_i} &= \mu F\left(\sum_{j=0}^{n_2} \omega_j s_j\right) [1 - F\left(\sum_{j=0}^{n_2} \omega_j s_j\right)] \left(\sum_{j=0}^{n_2} \omega_j \frac{\partial s_j}{\partial x_i}\right) \\ &= \mu F\left(\sum_{j=0}^{n_2} \omega_j s_j\right) [1 - F\left(\sum_{j=0}^{n_2} \omega_j s_j\right)] \\ &\quad \left[\mu \sum_{j=1}^{n_2} \omega_j \omega_j F\left(\sum_{k=0}^{n_1} \omega_{kj} x_k\right) (1 - F\left(\sum_{k=0}^{n_1} \omega_{kj} x_k\right))\right] \end{aligned} \quad (4)$$

由数学分析的理论可知, 该模型函数关于  $x_i$  可逆的充分条件是, 在其定义域内该函数关于  $x_i$  严格单调, 或者是  $\partial y / \partial x_i$  在定义域内恒正或恒负。若条件成立, 则可以通过神经网络求出  $x_i$  的值, 这些  $x_i$  和有关的输入变量值就是给定产品质量指标 (输入变量) 值的生产条件, 即以产品质量为输出变量值的新产品新工艺设计方案。

## 2 基于 BP 神经网络的胶液生成过程逆模型

### 2.1 胶液生成过程简介

胶液生成过程主要包括以下环节: 投料、溶解、抽真空浓缩消泡、放胶、储胶、降粘和断电冷却。为方便起见, 将其分为两个阶段: 即溶胶阶段和降黏阶段。

(1) 溶胶阶段: 首先将明胶、甘油和纯化水按一定比例投入溶胶罐, 经过一段时间的加热搅拌, 使其溶解, 此时需控制加热的温度和搅拌时间; 然后进行抽真空浓缩消泡, 此时需控制溶胶罐内温度, 真空度和抽真空时间; 最后是放胶, 将胶液放至储胶桶, 此时应将水分和胶液黏度控制在一定范围。

(2) 降黏阶段: 暂未使用的胶液于一定温度下进行保温。胶液使用前升温破坏黏度, 若为了快速降低黏度而使得升温时设定温度超过了最后胶液温度指标的要求, 还需要通过断

电冷却进行降温, 至胶液温度、黏度、水分等性能指标满足要求时, 即完成胶液生成过程。胶液生成工艺流程如图 4 所示。




图 4 胶液生成工艺流程图

## 2.2 基于 BP 神经网络的胶液生成过程逆模型多阶段建模

首先建立降黏阶段的逆模型, 该阶段以胶液生成过程最后的产品质量指标作为输入变量, 以相应的控制变量和来自上一阶段的输出变量作为本阶段的输出变量, 基于 BP 神经网络进行逆模型建模。通过对工艺过程和输入、输出数据进行分析, 确定该阶段关键输入变量 3 个, 分别为: 胶液温度  $K_3$ 、胶液粘度  $N_3$ 、水分  $W_3$ ; 关键输出变量 8 个, 依次为: 冷却时间  $t_4$ 、加热温度  $T_3$ 、加热时间  $t_3$ 、保温时间  $t_2$ 、保温温度  $T_2$ 、水分  $W_2$ 、胶液温度  $K_1$ 、胶液粘度  $N_1$ , 建立了一个  $3 \times 31 \times 8$  的 BP 网络, 第一层函数采用“tansig”, 第二层采用“logsig”函数, 用最速下降法进行训练。训练总步数取 1000 步, 目标误差取 0.001。训练目标函数采用的是误差平方和函数即

$$MSE = \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (5)$$

对生产的历史数据进行系统误差、随机误差和粗差的数据预处理, 以此作为样本信号, 对网络进行训练。

在训练网络之前, 要对输入输出数据进行归一化处理。对每一组样本数据, 归一化所采用的公式为:

$$y' = \frac{y - y_{\min}}{y_{\max} - y_{\min}} \quad (6)$$

其中  $y$ ,  $y'$  分别为归一化前后的数据,  $y_{\min}$ ,  $y_{\max}$  分别是该变量所有采样数据中的最小值和最大值。

将经过数据预处理和归一化后的 116 个样本组成的样本集  $S$  分成三部分, 分别记为样本集  $S_1$ 、 $S_2$ 、 $S_3$ ;  $S_1$  为训练集, 由 70 个样本组成, 用于训练和建模;  $S_2$ 、 $S_3$  为测试集, 各由 22 个样本组成。  $S_1$ 、 $S_2$  中的样本所用原材料明胶均来自产地  $A$ ;  $S_3$  原材料来自和训练集不同的产地  $B$  和  $C$ 。经过

学习后建立的降黏阶段子系统 BP 神经网络逆模型如图 5 所示。

基于相同的方法可以建立溶胶阶段的逆模型, 该阶段输入变量为水分  $W_2$ 、胶液温度  $K_1$ 、胶液粘度  $N_1$ , 水分  $W_0$ 、凝冻浓度  $C$ 、粘度  $N_0$ , 输出变量为加水量  $W_1$ 、加热温度  $T_1$ 、加热持续时间  $t_1$ 。




图 5 降黏阶段子系统的 BP 神经网络逆模型

## 2.3 基于 BP 神经网络的胶液生成过程逆模型整体建模

为了将多阶段建模和整体建模方法进行比较, 采用类似方法, 以胶液温度  $K_3$ 、胶液粘度  $N_3$ 、水分  $W_3$ 、水分  $W_0$ 、凝冻浓度  $C$ 、粘度  $N_0$  为输入变量, 冷却时间  $t_4$ 、加热温度  $T_3$ 、加热时间  $t_3$ 、保温时间  $t_2$ 、保温温度  $T_2$ 、加水量  $W_1$ 、加热温度  $T_1$ 、加热持续时间  $t_1$  为输出变量, 我们建立了一个  $6 \times 31 \times 8$  的 BP 神经网络模型。为了便于比较, 建模和测试所选用的样本集均和多阶段建模的样本集相同。

## 2.4 效果比较分析

采取多阶段建模和整体建模两种方法的命中率和测试命中比较见表 1, 其中命中率的定义为: 若某一样本点模型预测值和实际值的相对误差小于等于 5%, 称为命中, 此样本点称为合格点, 合格点占总样本数目的百分比称为命中率; 用所有的测试点进行测试时, 测试合格的点占总测试点数的百分比称为测试命中率。控制变量误差平方和 MSE 的比较见表 2。仿真结果表明采用本文提出的多阶段建模方法可以获得更高的命中率、测试命中率和较小的误差, 因此建模精度更高, 泛化能力更强。可以预计如果建模对象过程阶

表 1 测试集  $S_2$  中变量采用不同建模方法命中率及测试命中率比较

变量	命中率		测试命中率	
	多阶段建模	整体建模	多阶段建模	整体建模
加水量 $W_1$	1	1	1	1
加热温度 $T_1$	0.7717	0.7935	0.5455	0.5455
加热时间 $t_1$	0.8804	0.8043	0.9545	0.7273
保温温度 $T_2$	1	1	1	1
保温时间 $t_2$	0.9457	0.9457	0.9545	0.9091
加热温度 $T_3$	0.913	0.9239	0.8636	0.9091
加热时间 $t_3$	0.4674	0.9565	0.5	0.9545
冷却时间 $t_4$	0.9674	0.4565	1	0.4545
平均值	0.8682	0.8601	0.8523	0.8125

表 2 不同建模方法 MSE 的比较

方法	测试集 $S_2$ 的 MSE	测试集 $S_3$ 的 MSE
多阶段建模	0.3582	33.9123
整体建模	0.4205	35.6241

段数越多, 输入、输出变量越多, 这种差别会更明显; 这是因为胶液生成过程本身是多阶段的, 多阶段建模更符合过程的实际情况。

选取对胶液生成过程影响较明显的三个变量冷却时间  $t_4$ 、加热温度  $T_3$ 、保温时间  $t_2$  分别进行测试, 测试结果如图 6-8 所示。从图 6-8 均可以看出, 对于同一产地样本而言, 多阶段建模比整体建模效果略好; 对于不同产地样本而言, 预测值和实际值之间的偏差较大, 这说明来自不同产地的原材料其性质存在一定的差别, 因此对于不同产地的原材料需对其重新建模。




图 6 冷却时间  $t_4$  在不同情况下建模效果比较




图 7 加热温度  $T_3$  在不同情况下建模效果比较

同时, 利用逆模型方法可以由产品质量指标的要求变动求出操作变量的应有变动, 用于指导对工业生产工艺的操作或控制, 也可用于对工业生产的 product 设计和调整。如给出胶液生成过程最后的指标胶液温度  $K_3$ 、胶液粘度  $N_3$ 、水分  $W_3$ , 利用所建立的降黏阶段子系统逆模型和溶胶阶段子系统逆模型, 则可以依次推导出降黏阶段和溶胶阶段各控制变量的设定值。

通过对某制药公司一段时间的离线指导, 证明所建模型

和实际过程是吻合的, 对胶液生成过程工艺的改进和产品质量控制起到了指导作用。




图 8 保温时间  $t_2$  在不同情况下建模效果比较

### 3 结论

提出了一种基于 BP 神经网络的多阶段逆模型建模方法, 并应用于胶液生成过程的软测量建模, 主要结论如下:

- (1) 多阶段建模方法比整体建模精度高, 泛化能力强;
- (2) 多阶段建模方法具有更大的灵活性, 如果系统中某个环节发生变化, 那么只需要对该环节进行建模即可;
- (3) 面向最终产品质量的逆模型方法可以直接求出各个阶段的控制变量设定值, 更便于实际应用;
- (4) 用某一产地的原料和数据进行建模, 用不同产地原料的数据进行测试比用相同产地原料的数据进行测试所得的效果差, 说明不同产地的原料其性能有一定的差异, 因此其模型也存在一定的差异; 需要重新建立其相应模型。

### 参考文献:

- [1] 冯冬青, 张新征, 费敏锐. 基于回归神经网络的氧果合过程建模与仿真[J]. 系统仿真学报, 2005, 17(6): 1522-1530. (FENG Dong-qing, ZHANG Xin-zheng, FEI Min-rui. Recurrent neural network based modeling and simulation for the Omethoate synthesis process [J]. Journal of System Simulation (S1004-731X), 2005, 17(6): 1522-1530.)
- [2] 万百五. 工业大系统优化与产品质量控制[M]. 北京: 科学出版社, 2003.
- [3] 苗青, 曹广益, 朱新坚. 基于一种改进的 RBF 神经网络的直接甲醇燃料电池建模[J]. 系统仿真学报, 2005, 17(2): 284-289. (MIAO Qing, CAO Guang-yi, ZHU Xin-jian. Modeling direct methanol fuel cell (DMFC) based on improved RBF [J]. Journal of System Simulation (S1004-731X), 2005, 17(2): 284-289.)
- [4] 高学金, 王普, 孙崇正, 等. 基于支持向量机的青霉素发酵过程建模[J]. 系统仿真学报, 2006, 18(7): 2052-2055. (GAO Xue-jin, WANG Pu, SUN Chong-zheng, et al. Modeling for Penicillin fermentation process based on support vector machine [J]. Journal of System Simulation (S1004-731X), 2006, 18(7): 2052-2055.)
- [5] Shang-Ming Zhou, John Q Gan. Low-level interpretability and high-level interpretability: a unified view of data-driven interpretable fuzzy system modeling [J]. Fuzzy Sets and Systems (S0165-0114), 2008, 159(23): 3091-3131.

(下转第 1186 页)

使给煤量接近 12~15 吨, 同时监测电机的电流变化。电流值是用钳形电流表测量, 在给煤量达到额定值时, 分三次测量电机输入端的线电流, 测量结果如表 2 所示。




图 7 磨制水煤浆系统简图

表 2 电流测量数据

测量次数	1	2	3
电流(A)	23.6	24.2	25.1

从表中数据得到平均电流值为 24.3A, 电流没有超过电机额定电流范围, 也没再出现因电机功率不足而停车的现象。

此外, 电机的输出功率可以用下面公式表示为<sup>[12]</sup>:

$$P = \sqrt{3}U_1 I_1 \eta \cos\varphi \quad (12)$$

式中,  $P$  为电机输出功率;  $U_1$  为输入端线电压;  $I_1$  为线电流;  $\eta$  为电机效率;  $\cos\varphi$  为电机功率因数。由于载荷接近额定载荷, 因此可假设电机的输入端电压、电机效率、功率因数为额定值, 将测定的电流平均值代入公式(12)中得到电机功率为 218kW。该计算结果与根据仿真结果利用公式(11)计算的行星磨的功耗数值有较好的一致性。

## 5 结论

磨碎设备的功耗问题是复杂的多学科交叉性问题, 长期以来其研究工作都是以经验公式为基础的。本文利用车辆-地面力学、土力学和有限元数值分析为研究手段, 对

立式行星磨的磨碎功耗问题进行了分析, 计算结果与试验结果相符合, 对立式行星磨的设计与使用具有指导意义。综合起来, 得到如下结论:

(1) 直接采用 Bekker 刚性轮压实阻力计算公式不适合计算行星轮的滚动阻力, 需要进一步修正该公式;

(2) 用有限元数值分析来研究立式行星磨行星轮的滚动阻力问题是有效的, 能较准确地计算出行星轮的滚动阻力;

(3) LXM1200 型行星磨行星轮数目为 8 个, 行星轮转动半径为 0.47m, 角速度为 20.94rad/s 时, 立式行星磨的平均磨碎功率为 227kW, 与实际所需功率相符合。

## 参考文献:

- [1] 郝雪弟, 卞致瑞, 刘立, 等. 立式行星磨磨腔内流场的三维数值模拟[J]. 冶金设备, 2004, 158(4): 14-17.
- [2] 孙春宝, 李睿华, 卢寿慈, 等. Szego 磨的工作原理及其特点[J]. 矿山机械, 1998, 26(7): 18-20.
- [3] 李瑞涛, 彭龙洲, 谢理. 立式行星磨系统动力学分析[J]. 金属矿山, 2000, 291(9): 37-38.
- [4] WANJII S, HIROMA T, OTA Y, *et al.* Prediction of wheel performance by analysis of normal and tangential stress distributions under the wheel-soil interface [J]. Journal of Terramechanics (S0022-4898), 1997, 34(3): 165-186.
- [5] SHMULEVICH I, MUSSEL U, WOLF D. The effect of velocity on rigid wheel performance [J]. Journal of Terramechanics (S0022-4898), 1998, 35(3): 189-207.
- [6] SHIBLY H, IAGNEMMA K, DUBOWSKY S. An equivalent soil mechanics formulation for rigid wheels in deformable terrain, with application to planetary exploration rovers [J]. Journal of Terramechanics (S0022-4898), 2005, 42(1): 1-13.
- [7] FUKAMI K, MASAMI U, HASHIGUCHI K, *et al.* Mathematical models for soil displacement under a rigid wheel [J]. Journal of Terramechanics (S0022-4898), 2006, 43(3): 287-301.
- [8] 张克健. 车辆地面力学[M]. 北京: 国防出版社, 2002.
- [9] RAPER R L, JOHSON C E, BEILEY A C, *et al.* Prediction of Soil Stresses Beneath a Rigid Wheel [J]. J. Agric. Engng Res (S0021-8634), 1995, 61(1): 57-62.
- [10] CHIROUX R C, FOSTER W A, JOHSON C E, *et al.* Three-dimensional finite element analysis of soil interaction with a rigid wheel [J]. Applied Mechanics and computation (S0096-3003), 2005, 162(2): 707-222.
- [11] 张学言, 闫澍旺. 岩土塑性力学基础[M]. 天津: 天津大学出版社, 2004.
- [12] 王益全, 张炳义, 等. 电机测试技术[M]. 北京: 科学出版社, 2004.

(上接第 1181 页)

- [6] E J M Carranza, F J A van Ruitenbeek, C Hecker, *et al.* Knowledge-guided data-driven evidential belief modeling of mineral prospectivity in Cabo de Gata [J]. International Journal of Applied Earth Observation and Geoinformation (S0303-2434), 2008, 10(3): 374-387.
- [7] Eleni Aggelogiannaki, Haralambos Sarimveis. Nonlinear model predictive control for distributed parameter systems using data driven artificial neural network models [J]. Computers & Chemical

- Engineering (S0098-1354), 2008, 32(6): 1225-1237.
- [8] Hadiyantoa, D. C. Esveld, R. M. Boom, *et al.* Product quality driven design of bakery operations using dynamic optimization [J]. Journal of Food Engineering (S0260-8774), 2008, 86(3): 399-413.
- [9] Patricia Melin, Oscar Castillo. An intelligent hybrid approach for industrial quality control combining neural networks, fuzzy logic and fractal theory [J]. Information Sciences (S0020-0255), 2007, 177(7): 1543-1557.