

文章编号: 1000-8152(2009)03-0316-05

基于PNN和IGS的铅锌烧结块成分智能集成预测模型

王春生¹, 吴 敏¹, 余锦华²

(1. 中南大学 信息科学与工程学院, 湖南 长沙 410083; 2. 东京工科大学 计算机科学学部, 日本 东京 192-0982)

摘要: 针对复杂的烧结块成分预测问题, 提出一种基于过程神经网络和改进灰色系统的铅锌烧结块成分智能集成预测模型。首先利用过程神经网络可充分表达时间序列中时间累积效应、灰色系统可弱化数据序列波动性的特点, 分别对烧结块成分进行预测, 然后从信息论的观点出发, 提出一种确定各预测模型加权系数的熵值递推算法, 通过对两个预测模型的预测结果进行加权集成, 获得更加准确的铅锌烧结块成分预测结果。结果表明, 智能集成模型的预测精度高于单一预测模型, 能有效地对烧结块成分进行预测, 满足了配料计算对预测精度和数据完备性的要求。

关键词: 铅锌烧结过程; 成分预测; 过程神经网络; 改进灰色系统; 信息熵; 智能集成预测模型

中图分类号: TP273 文献标识码: A

An intelligent integrated-prediction model for components of Pb-Zn agglomerate based on the process neural network(PNN) and the improved grey system(IGS)

WANG Chun-sheng¹, WU Min¹, SHE Jin-hua²

(1. School of Information Science and Engineering, Central South University, Changsha Hunan 410083, China;
2. School of Computer Science, Tokyo University of Technology, Hachioji, Tokyo, 192-0982, Japan)

Abstract: To deal with the problem of the component prediction for Pb-Zn agglomerate, an intelligent integrated-prediction model based on the process neural network(PNN) and the improved grey system(IGS) is presented. First, the component of agglomerate is predicted by PNN and IGS models, and then, a recursive entropy algorithm for the weighting coefficients is devised from the viewpoint of the information theory. The component of Pb-Zn agglomerate is predicted by integrating the two prediction models. Application results show that the integrated model has high prediction accuracy; it predicts the components of agglomerate efficiently and meets the data-completeness requirements for proportioning computation.

Key words: lead-zinc sintering process; prediction of component; process neural network; improved grey system; information entropy; intelligent integrated-prediction model

1 引言(Introduction)

在铅锌密闭鼓风炉火法冶炼中, 烧结过程的主要作用是将铅锌精矿氧化脱硫并固结成块, 得到的烧结块作为鼓风冶炼的原料。从烧结混合料到烧结块经过了一系列物理化学变化, 具有严重的非线性、强耦合和大滞后, 过程影响因素繁多而可测量信息有限, 因此很难实现对烧结块成分的实时准确预测。烧结块中的铅锌含量是烧结生产的重要指标参数之一, 实现对烧结块成分铅锌含量的实时准确预测, 对于优化烧结配料、控制烧结块成分以及稳定熔炼生

产都具有非常重要的意义。

针对烧结块成分预测问题, 一些学者进行了深入研究^[1,2]。这些研究表明, 对于复杂的铅锌烧结过程而言, 单一预测模型的预测精度不高, 无法准确对烧结块成分进行有效预测。采用智能集成建模方法已成为解决复杂生产过程建模问题的主要手段之一, 并在相关领域得到了成功应用^[3,4]。

本文针对复杂的铅锌烧结块成分预测问题, 将基于过程神经网络的时间序列预测模型与改进灰色系统预测模型的优势相结合, 提出一种智能集成预测

收稿日期: 2007-07-18; 收修改稿日期: 2008-06-13。

基金项目: 国家杰出青年科学基金资助项目(60425310); 国家863计划课题(2008AA04Z128)。

模型。该模型首先利用过程神经网络可充分表达时间序列中存在的时间累积效应以及改进灰色系统可弱化数据波动性的优势, 分别对烧结块成分进行预测, 然后基于信息论中熵值的概念, 提出一种确定各预测模型加权系数的熵值递推算法, 并对两个单一预测模型的预测结果进行加权集成。研究表明: 该集成预测模型可实现烧结块成分的可靠、准确预测, 具有较高的预测精度, 预测结果为烧结配料优化提供了依据和数据支持。

2 铅锌烧结过程机理分析(Lead-zinc sintering process mechanism analysis)

铅锌烧结过程作为铅锌火法冶炼过程的第一道工序, 其目的不仅使硫化矿氧化为氧化物, 同时又使部分氧化生成物与熔剂结合, 引起固结, 形成具有较大机械强度和还原性且满足鼓风还原熔炼条件的烧结块, 并作为鼓风炉还原熔炼的原料。

铅锌烧结的原料经过一次配料和二次配料以后, 粉状混合料经过混料圆筒和制粒圆筒成为具有合适水分的混合料球。混合料球通过梭式布料机分别送入点火仓和主料仓, 点火仓的混合料球布到烧结机的台车上形成约3 cm厚的薄层矿料, 称为点火层。在烧结机机头后部主料仓再布上混合料, 形成约30~40 cm厚的总料层。由于混合料含硫较高, 硫化物氧化反应放出的热量使反应扩展到整个物料层, 无需外加燃料即可保证整个鼓风烧结焙烧过程。

通过调节煤气流量控制合适的点火温度, 对点火层混合料进行点火。点火后的混合料跟随台车一起移动, 经过干燥、加热、反应、烧结4个过程, 混合料球烧结成为具有一定结构的烧结块料, 并在烧结机尾产出。烧结块料经过两级破碎, 大小合适的烧结块料成为烧结块进入熔炼工艺流程; 规格不合适的烧结块料再经过两级破碎成为返粉, 重新进入烧结二次配料流程。

在经历一系列复杂的物理化学反应后, 最终得到符合工艺指标要求的烧结块。铅锌烧结块成分的预测具有灰色特性, 主要表现在以下3个方面:

1) 表征烧结块成分的数据是灰色数。由于烧结过程物理化学反应异常复杂, 烧结过程中的各种外界噪音的干扰以及烧结块成分检测仪器的误差等原因, 现场测量得到的数据都是有一定误差的灰色数, 或者说形式上是白色数。诸如铅成分含量、锌成分含量等数据, 均可看成是在真实值的某个邻域内变化的灰色数。

2) 影响烧结块成分的因素是灰色的。影响烧结块成分的因素较多, 如烧结原料的性能、烧结一次和二次配料的配比、点火温度、台车速度、风机风

量、料层透气性、烧结终点位置等, 很难确定影响烧结块成分的所有因素, 有许多因素不完全明确, 有些已经明确的又难以进行量化描述, 能够量化的有可能具有随机性。

3) 影响烧结块成分的某些关系是灰关系。影响烧结块成分的各个因素之间存在着耦合关系, 这种耦合关系难以精确描述。另外, 由于经验知识水平的高低差异, 不同操作人员在实际生产过程中的某些方面控制作用的偏差或生产工况的波动也会给烧结块成分带来波动, 这种关系也同样难以准确地描述。

基于上述分析, 本文采用灰色系统理论建立烧结块成分预测模型, 同时, 考虑到烧结块成分的预测可以看成是一个时间序列预测问题, 因此采用可反映时间累积效应的过程神经网络进行建模, 建立基于过程神经网络的时间序列预测模型。最后利用信息熵的概念, 提出一种确定各预测模型加权系数的熵值递推算法, 对上述模型进行加权集成。

3 过程神经网络时间序列预测模型(Process neural network time series prediction model)

过程神经网络在结构上与传统的人工神经网络^[5]类似, 不同之处在于过程神经网络的输入和相应的连接权是时变函数^[6]。过程神经网络由于增加了一个时间聚合运算算子, 因此, 能充分反映时间序列中存在的时间累积效应。

本文提出的基于过程神经网络的铅锌烧结块成分时间序列预测模型是一种3层前向过程神经网络, 其拓扑结构为1-10-1, 如图1所示。

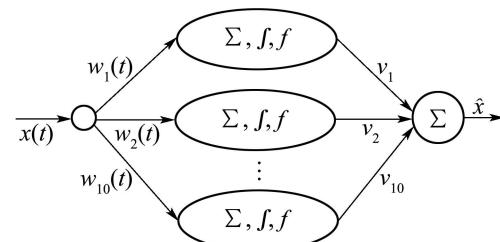


图1 过程神经网络预测模型

Fig. 1 Process neural network prediction model

基于过程神经网络的烧结块成分时间序列预测模型为

$$\hat{x} = \sum_{i=1}^{10} v_i f(\int_0^T w_i(t)x(t)dt - \theta_i) - \theta, \quad (1)$$

其中: $x(t)$ 是过程神经元的输入函数, $[0, T]$ 是样本采样区间, $w_i(t)$ 为相应的连接权函数, v_i 为隐层节点到输出节点的连接权值, θ 为过程神经元阈值, $f(\cdot)$ 为激励函数。

根据Weierstrass逼近定理并通过Gram-Schmidt正交化步骤, 可以得到在 $C[0, T]$ 空间上的一组标

准正交基函数 $b_j(t)$, 则 $x(t), w_i(t)$ 可分别表示为

$$x(t) = \sum_{j=1}^J a_j b_j(t), \quad w_i(t) = \sum_{j=1}^J w_{ij} b_j(t), \quad (2)$$

其中 $a_j, w_{ij} \in \mathbb{R}$ 为展开式系数.

根据正交函数的性质, 式(1)可简化为

$$\hat{x} = \sum_{i=1}^{10} v_i f\left(\sum_{j=1}^J w_{ij} a_j - \theta_i\right) - \theta. \quad (3)$$

给定 L 组学习样本 $\{x_l(t), q_l\}$ ($l = 1, 2, \dots, L$), q_l 为对应于样本 $x_l(t)$ 的网络期望输出. 设 x_l 为相应的网络实际输出, 则网络模型的误差函数可定义为

$$E = \frac{1}{2} \sum_{l=1}^L (\hat{x}_l - q_l)^2 = \frac{1}{2} \sum_{l=1}^L \left(\sum_{i=1}^{10} v_i f\left(\sum_{j=1}^J w_{ij} a_{jl} - \theta_i\right) - \theta - q_l \right)^2. \quad (4)$$

记 $X_{il} = \sum_{j=1}^J w_{ij} a_{jl} - \theta_i$. 根据最速梯度下降算法, 网络模型的待训练参数调整规则为

$$\begin{cases} v_i(s+1) = v_i(s) + \alpha \Delta v_i(s), \\ w_{ij}(s+1) = w_{ij}(s) + \beta \Delta w_{ij}(s), \\ \theta_i(s+1) = \theta_i(s) + \gamma \Delta \theta_i(s), \\ \theta(s+1) = \theta(s) + \delta \Delta \theta(s), \end{cases} \quad (5)$$

其中: α, β, γ 和 δ 为学习速率, s 为学习迭代次数.

在每一次的学习迭代中, $\Delta v_i, \Delta w_{ij}, \Delta \theta_i$ 和 $\Delta \theta$ 可分别表示为

$$\begin{cases} \Delta v_i = -\frac{\partial E}{\partial v_i} = -\sum_{l=1}^L (\hat{x}_l - q_l) f'(X_{il}), \\ \Delta w_{ij} = -\frac{\partial E}{\partial w_{ij}} = -\sum_{l=1}^L (\hat{x}_l - q_l) v_i f'(X_{il}) a_{jl}, \\ \Delta \theta_i = -\frac{\partial E}{\partial \theta_i} = \sum_{l=1}^L (\hat{x}_l - q_l) v_i f'(X_{il}), \\ \Delta \theta = -\frac{\partial E}{\partial \theta} = \sum_{l=1}^L (\hat{x}_l - q_l). \end{cases} \quad (6)$$

具体的学习过程描述如下:

Step 1 采用Legendre正交基函数将过程神经网络模型的输入函数和连接权函数表示为基函数的展开形式;

Step 2 给定学习迭代次数 $s = 0$, 学习误差精度 ϵ , 学习速率: $\alpha, \beta, \gamma, \delta$ 和最大学习迭代次数 D ;

Step 3 初始化权值和阈值;

Step 4 根据式(4)计算误差函数 E , 若 $E < \epsilon$ 或 $s > D$, 则转Step 6结束, 否则转Step 5;

Step 5 按式(5)和式(6)的规则调整权值和阈值, $s + 1 \rightarrow s$, 并转至Step 4;

Step 6 输出学习结果, 结束.

4 改进灰色系统预测模型(Improved grey system prediction model)

传统的灰色预测模型对于历史记录较短、零散分布的数据序列, 往往会产生欠拟合或过拟合现象, 导致预测精度降低^[7]. 基于此, 本文采用均值平滑法, 提出了一种改进的灰色系统预测模型. 在保留传统灰色预测模型优点的基础上, 克服了传统模型的不足, 使所建模型具有弱化数据波动的能力.

已知某冶炼厂烧结块成分铅锌含量的原始数据序列为 $X^{(0)} = \{x^{(0)}(1), x^{(0)}(2), \dots, x^{(0)}(n)\}$, 考虑到运用灰色模型预测时, 如果原始数据有较大波动, 容易造成预测结果不准确^[8,9], 误差较大, 为减弱突变值的影响, 均衡原始数列的趋势, 尽量使原始数列趋势与指数的递增规律保持一致, 进而提高预测的精度, 本文采用均值平滑法, 引入均值生成算子 $x^*(k) = 0.5x(k) + 0.5x(k-1)$ 对烧结块成分原始数据进行平滑处理, 得到平滑后的序列 $X^{(0)*}$, 然后对其进行1阶累加生成序列 $X^{(1)}$:

$$X^{(1)} = \{x^{(1)}(1), x^{(1)}(2), \dots, x^{(1)}(n)\}, \quad (7)$$

$$x^{(1)}(k) = \sum_{i=1}^k x^{(0)*}(i). \quad (8)$$

建立白化微分方程

$$\frac{dx^{(1)}}{dt} + ax^{(1)} = b, \quad (9)$$

式中: a 为模型的发展系数, 反映铅锌含量原始数据序列 $X^{(0)}$ 和1阶累加生成序列 $X^{(1)}$ 的发展趋势; b 为模型的协调系数, 反映数据之间的变化关系.

记 $A = [a, b]^T$, 用最小二乘法按下式确定参数:

$$A = (B^T B)^{-1} B^T Y_N, \quad (10)$$

式中:

$$B = \begin{bmatrix} -0.5(x^{(1)}(1) + x^{(1)}(2)) & 1 \\ -0.5(x^{(1)}(2) + x^{(1)}(3)) & 1 \\ -0.5(x^{(1)}(3) + x^{(1)}(4)) & 1 \\ \vdots & \vdots \\ -0.5(x^{(1)}(n-1) + x^{(1)}(n)) & 1 \end{bmatrix},$$

$$Y_N = [x^{(0)}(2) \ x^{(0)}(3) \ x^{(0)}(4) \ \cdots \ x^{(0)}(n)]^T.$$

将求得的 a 和 b 代入式(9), 通过求解微分方程得

$$x^{(1)}(k+1) = [x^{(0)}(1) - \frac{b}{a}]e^{-ak} + \frac{b}{a}, \quad k = 0, 1, \dots. \quad (11)$$

对上式做累减生成还原, 得到烧结块成分铅锌含量原始数列 $X^{(0)}$ 灰色预测模型为

$$\hat{x}^{(0)}(k) = \hat{x}^{(1)}(k) - \hat{x}^{(1)}(k-1), \quad k = 1, 2, \dots. \quad (12)$$

5 基于信息熵的集成预测模型(Integrated prediction model based on entropy)

为了使预测结果尽可能接近烧结块成分铅锌含量的实际值, 提高预测精度, 基于集成思想, 提出确定加权系数的熵值递推算法, 将上述两个单一模型进行加权集成, 建立烧结块成分集成预测模型, 综合两个模型的输出作为最终的预测结果。

设 x_t 为烧结块成分的实际值, m 为单一预测模型的个数(本文中 $m = 2$), \hat{x}_{it} 为第*i*个单一预测模型在第*t*时刻的预测值, 则集成预测模型的预测值为

$$\hat{x}_t = \sum_{i=1}^m w_i \hat{x}_{it}, \quad i = 1, \dots, m. \quad (13)$$

其中 w_i 为第*i*个单一预测模型的加权系数, w_i 满足

$$\sum_{i=1}^m w_i = 1, \quad w_i \geq 0, \quad i = 1, \dots, m. \quad (14)$$

第*i*个预测模型在第*t*时刻的预测相对误差为

$$e_{it} = \begin{cases} \left| \frac{x_t - \hat{x}_{it}}{x_t} \right|, & \text{如果 } 0 \leq \left| \frac{x_t - \hat{x}_{it}}{x_t} \right| < 1, \\ 1, & \text{如果 } \left| \frac{x_t - \hat{x}_{it}}{x_t} \right| \geq 1. \end{cases} \quad (15)$$

本文利用信息熵^[10,11]的概念, 重新定义预测模型预测误差序列的变异程度。以预测模型当前时刻*t*和下一时刻*t+1*的预测相对误差为基础, 建立预测相对误差序列, 提出确定加权系数的熵值递推算法, 其步骤如下:

Step 1 初始化参数 $m, t, i = 1, n = 0$ 。

Step 2 读取第*i*个预测模型在第*t*时刻的预测相对误差 e_{it} , 并置 $n = n + 1$ 。

Step 3 判断 $n = 2$ 否, 若是, 则转下步; 否则 $t = t + 1$, 转Step 2。

Step 4 计算第*i*个预测模型在第*t*时刻的预测相对误差的比重 p_{it} :

$$p_{it} = \frac{e_{it}}{e_{it} + e_{i,t+1}}. \quad (16)$$

Step 5 计算第*i*个单一预测模型的预测相对误差的熵值 E_{it} :

$$E_{it} = -r(p_{it} \ln p_{it} + p_{i,t+1} \ln p_{i,t+1}), \quad (17)$$

其中 $r > 0$, 本文取 $r = 1/\ln n$ 。

Step 6 计算第*i*个单一预测模型预测相对误差序列的变异程度系数 d_{it} 。根据预测相对误差的熵值大小与其变异程度相反的原则, 第*i*个单一模型预测相对误差序列的变异程度系数 d_{it} 为

$$d_{it} = 1 - E_{it}, \quad i = 1, \dots, m. \quad (18)$$

Step 7 判断 $i = m$ 否, 若是, 则转下步; 否则 $i = i + 1, t = t - 1$, 转Step 2。

Step 8 计算输出第*i*个单一预测模型在第*t*时刻的加权系数 w_{it} :

$$w_{it} = \frac{1}{m-1} \left(1 - \frac{d_{it}}{\sum_{i=1}^m d_{it}} \right). \quad (19)$$

Step 9 计算输出集成预测模型的预测值 \hat{x}_t :

$$\hat{x}_t = \sum_{i=1}^m w_{it} \hat{x}_{it}. \quad (20)$$

6 结果分析与结论(Results analysis and conclusions)

针对某冶炼厂烧结块成分铅锌含量预测问题, 分别建立PNN和IGS预测模型, 依照上述确定加权系数的熵值递推算法, 分别得到铅含量和锌含量预测各模型的加权系数, 其变化曲线如图2和图3所示。铅锌成分含量的预测结果如图4和图5所示。

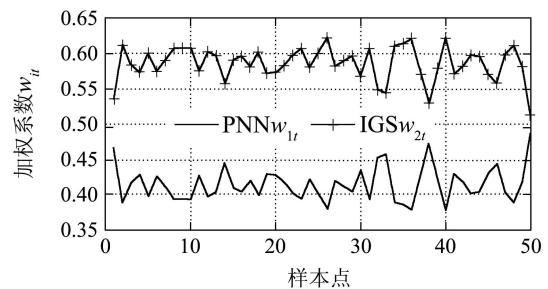


Fig. 2 Weighting coefficients of two single models for Pb component prediction

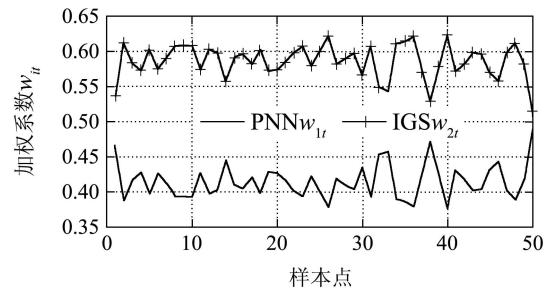


Fig. 3 Weighting coefficients of two single models for Zn component prediction

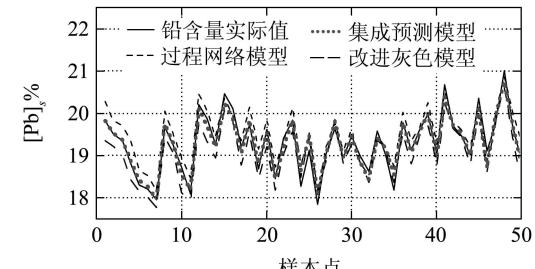


Fig. 4 Prediction results of Pb component in the agglomerate

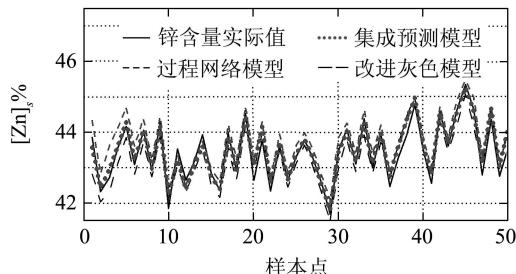


图5 锌含量预测结果

Fig. 5 Prediction results of Zn component in the agglomerate

本文针对烧结块成分预测问题,在建立过程神经网络时间序列预测模型和改进灰色模型的基础上,从信息论的观点出发,提出了一种确定各预测模型加权系数的熵值递推算法,建立了智能集成预测模型,它将过程神经网络时间序列预测模型和改进灰色系统预测模型的预测结果进行加权集成,作为最终的烧结块成分铅锌含量预测值。将其预测性能与单一预测模型进行比较,结果表明:利用本文方法所建立的集成预测模型能够获得更高的预测精度,其预测效果和性能优于过程神经网络模型和改进灰色预测模型。本文提出的智能集成方法较好地解决了复杂的烧结块成分预测问题,是一种有效的预测方法,其预测结果为烧结过程配料优化计算提供了依据。

参考文献(References):

- [1] 陈晓方,桂卫华,王雅琳,等.基于智能集成策略的烧结块残硫软测量模型[J].控制理论与应用,2004,21(1): 75–80.
(CHEN Xiaofang, GUI Weihua, WANG Yalin, et al. Soft-sensing model of sulfur content in agglomerate based on intelligent integrated strategy[J]. *Control Theory & Applications*, 2004, 21(1): 75–80.)
- [2] 王雅琳,桂卫华,阳春华,等.基于综合建模方法的铅锌烧结块成分预测[J].中南大学学报(自然科学版),2005,36(1): 113–118.
(WANG Yalin, GUI Weihua, YANG Chunhua, et al. Prediction for composition of Pb-Zn agglomerate based on integrated modeling[J]. *Journal of Central South University(Science and Technology)*, 2005, 36(1): 113–118.)
- [3] WU M, XU C H, DU Y X. Intelligent optimal control for lead-zinc sintering process state[J]. *Transactions of Nonferrous Metals Society of China*, 2006, 16(4): 975–981.
- [4] XU W X, WEI Y M. Multiple objective-integrated methodology of global optimum decision-making on mineral resources exploitation[J]. *Computers and Industrial Engineering*, 2004, 46(2): 363–372.
- [5] FRANK R J, DAVEY N, HUNT S P. Time series prediction and neural networks[J]. *Journal of Intelligent and Robotic Systems: Theory and Applications*, 2001, 31(3): 91–103.
- [6] 丁刚,钟诗胜.具有时变输入输出函数的反馈过程神经网络及应用[J].控制与决策,2007,22(1): 91–94.
(DING Gang, ZHONG Shisheng. Feedback process neural network with time-varying input and output functions and its applications[J]. *Control and Decision*, 2007, 22(1): 91–94.)
- [7] YAO W L, CHI S C, CHEN J H. An Improved grey-based approach for electricity demand forecasting[J]. *Electric Power Systems Research*, 2003, 67(3): 217–224.
- [8] LIN Y H, LEE P C. Novel high-precision grey forecasting model[J]. *Automation in Construction*, 2007, 16(6): 771–777.
- [9] 孙才新,毕为民,周濂,等.灰色预测参数模型新模式及其在电气绝缘故障预测中的应用[J].控制理论与应用,2003,20(5): 797–801.
(SUN Caixin, BI Weimin, ZHOU Quan, et al. New gray prediction parameter model and its application in electrical insulation fault prediction[J]. *Control Theory & Applications*, 2003, 20(5): 797–801.)
- [10] MOHAMED S. Estimating market shares in each market segment using the information entropy concept[J]. *Applied Mathematics and Computation*, 2007, 190(2): 1735–1739.
- [11] 杨慧中,王军霞,丁锋.一种综合信息熵和遗传算法的知识简约方法[J].控制理论与应用,2006,23(6): 891–894.
(YANG Huizhong, WANG Junxia, DING Feng. Knowldge reduction approach based on information entropy and GA[J]. *Control Theory & Applications*, 2006, 23(6): 891–894.)

作者简介:

王春生 (1966—),男,副教授,主要研究方向为复杂系统建模与优化控制,E-mail: wangcsu@mail.csu.edu.cn;

吴敏 (1963—),男,教授,博士生导师,主要研究方向为过程控制、鲁棒控制和智能系统,E-mail: min@csu.edu.cn;

余锦华 (1963—),男,东京工科大学副教授,主要研究方向为鲁棒控制、智能控制和过程控制,E-mail: she@cc.teu.ac.jp.