

纸浆洗涤过程双目标优化分布式控制系统*

汤 伟^{1,2}, 施颂椒¹, 赵小梅³, 王孟效², 郑恩让²

(1. 上海交通大学 自动化系, 上海 200030; 2. 西北轻工业学院 自动化系, 陕西咸阳 712081;
3. 浙江大学 工业控制研究所, 浙江杭州 310027)

摘要: 提出了一套新型纸浆洗涤过程 DCS 控制方案. 基本控制思想是: 通过控制真空洗浆机进浆流量和进浆浓度、黑液喷淋量、洗浆机液位和清水注入量来保证洗涤质量; 通过两步辨识法建立洗后浆残碱量和首段黑液波美度的神经网络模型, 并对清水加入量和产量进行双目标优化. 采用新华 XDPS 软件平台实现了纸浆洗涤过程的 DCS 控制. 系统已投入运行, 控制效果良好.

关键词: 纸浆洗涤过程; 分布式控制系统; 两步辨识法; 多目标优化

图中文分类号: TP273+.1

文献标识码: A

Pulp washing process DCS based on double-objective optimization

TANG Wei^{1,2}, SHI Song-jiao¹, ZHAO Xiao-mei³, WANG Meng-xiao², ZHENG En-rang²

(1. Automation Department, Shanghai Jiaotong University, Shanghai 200030, China;

2. Automation Department, Northwest Institute of Light Industry, Shanxi Xianyang 712081, China;

3. Industrial Control Research Institute, Zhejiang University, Hangzhou 310027, China)

Abstract: A novel pulp washing process DCS (distributed control system) is proposed. The basic control strategy is just as below. The pulp washing quality is guaranteed by regulating the inlet stock flow and consistency of filter washer, black liquor showering flow, washer level and green water inlet flow. The neural network models of the residual soda of washed pulp and the Baume degree of the first stage black liquor are modeled via two-step identification method. At last a double-objective optimization of the green water input and washed pulp output is done. The DCS is implemented successfully on XDPS platform of Xinhua Company Limited. It has been in operation and improved the pulp washing quality greatly.

Key words: pulp washing process; DCS; two-step identification method; multi-objective optimization

1 引言(Introduction)

纸浆洗涤的主要目的是将纸浆中的可溶无机物和有机物洗净, 同时获得高浓度的黑液. 这两个要求相互矛盾, 但有效的控制方案可以调解这对矛盾, 提高洗涤质量.

国外对纸浆洗涤过程的控制已有 20 余年的历史, 积累了丰富的操作经验, 并产生了几种典型的控制方案^[1]: 黑液浓度控制、残碱量控制、稀释因子的优化控制、基于模型的优化控制和多组分控制等. 我国在这方面的研究起步较晚, 控制水平与国外相比亦存在相当的差距^[2]. 目前国内对纸浆洗涤过程的控制多采用黑液浓度控制. 此方案控制效果差, 在国外已逐渐被淘汰. 国外的洗涤控制系统往往与打浆设备及工艺流程配套, 国内大多数纸厂因缺乏资金, 没有能力全套引进; 国内浆种多样, 国外系统未必适

用. 因此, 研究开发适合我国纸厂工艺及设备现状的纸浆洗涤过程控制系统是一个亟待解决的问题.

本文提出了一套新型的纸浆洗涤过程 DCS 控制方案, 其中包括浓度控制子系统、液位控制子系统、流量控制子系统、温度控制子系统及双目标优化控制子系统. 其基本控制思想是: 通过控制真空洗浆机进浆流量和进浆浓度、黑液喷淋量、洗浆机液位和清水注入量来保证洗涤质量, 通过两步辨识法建立洗后浆残碱和首段黑液波美度的神经网络模型, 并对清水加入量和产量进行双目标优化. 采用新华 XDPS 为软件平台实现了对纸浆洗涤过程的 DCS 控制.

2 工艺流程简介(Crafts and arts of pulp washing process)

普通国产四段真空洗浆机采用逆流洗涤原理,

* 基金项目: 国家“九·五”攻关项目(97-619-02-03)资助.

收稿日期: 2000-12-01; 收修改稿日期: 2001-05-18.

工艺流程如图 1 所示(a 为热水或浓缩段来热黑液; b 为黑液去蒸煮工段和碱回收车间). 来自蒸煮车间的粗浆在喷放锅内经稀释后由上浆泵打出, 经加黑液稀释后进入 I 段真空洗浆机, 由 II 段黑液桶来的黑液进行喷淋洗涤. 产生的黑液进入 I 段黑液桶, 洗后浆由压料辊送入 II 段真空洗浆机, 由 III 段黑液桶来的黑液进行喷淋洗涤. 如此进行下去. 当浆进入 IV 段真空洗浆机时, 用清水或浆料浓缩段黑液进行喷淋洗涤, 洗后黑液进入本段黑液桶, 洗后浆被送到洗后浆塔, 等待筛选工段筛选. 在整个过程中, 浆与洗涤液的流向是反向的. 浆由 I 段进入 IV 段, 残碱越来越小; 洗涤液由 IV 段逆流到 I 段, 波美度越来越高.




图 1 纸浆洗涤工艺流程示意图

Fig. 1 The crafts and arts of pulp washing process

3 控制系统总体方案(The general scheme of control system)

根据工艺指标的具体要求, 设计了图 2 所示的基于新华 XDPS 软件开发平台的 DCS 控制系统. 系统由四台工控机构成两级 DCS. 其中三台为操作员站(OPU), 用于画面显示、报警、泵和电机的手/自动启停以及现场各被控参数的采集、显示和控制. 操作员对现场的监视和操作都是通过这三台工控机来完成的. 另一台工控机为工程师站(ENG), 用于工程师对生产现场的监视、打印报表以及对工艺参数和控制器参数的修改等. 系统设置了三级网络: 厂级 MIS 网、信息网和实时网. 其中实时网用于现场数据与工控机间的信息交换, 信息网用于工控机之间的信息交换以及工控机与厂级网之间的信息交换.




图 2 纸浆洗涤过程 DCS 示意图

Fig. 2 The DCS of pulse washing process

在控制方面, 系统包含浓度控制子系统、液位控制子系统、流量控制子系统、温度控制子系统及双目标优化控制子系统. 其中, 前四个子系统的作用是保证浆料逆流洗涤的正常进行, 使洗后浆的残碱尽可能地小, 而 I 段黑液桶中黑液波美度尽可能地大; 双目标优化控制子系统的作用是在保证工艺对残碱及波美度的要求的前提下, 使系统消耗的清水最少而产量最高, 从而达到节能降耗保护环境的目的, 并进一步优化残碱和波美度.

本控制系统除了在硬件方面采用了冗余电源、冗余连接和冗余数据处理单元(DPU)之外, 在软件方面也采用了有效的冗余技术和品质测试技术. 因此控制系统的可靠性很高.

4 残碱量和波美度的神经网络建模(NN models of residual soda and Baume degree)

4.1 数学模型描述(Mathematical model description)

为建立纸浆洗涤过程数学模型, 根据工艺指标要求选取如下输入输出变量. 输入变量: 上浆流量 x_1 (m^3/h)、上浆浓度 x_2 (Kg/m^3)、清水流量 x_3 (m^3/h); 输出变量: 洗后浆残碱 $\bar{y}_1$ (g/l)、I 段黑液桶波美度 $\bar{y}_2$ (Be). (实际上, 为了方便且准确地测量, 这里的 $\bar{y}_1$ 代表 IV 段黑液桶中黑液含碱量. 洗后浆残碱与 IV 段黑液桶中黑液含碱量之间的对应关系可通过实际观测得到). 神经网络稳态模型可表示为

$$\begin{cases} \bar{y}_1 = f_1(x_1, x_2, x_3), \\ \bar{y}_2 = f_2(x_1, x_2, x_3). \end{cases} \quad (1)$$

神经网络动态模型可表示为:

$$\begin{cases} \bar{y}_1 = h_1(x_1(k), x_1(k-1), \dots, x_1(k-d), x_2(k), x_2(k-1), \dots, x_2(k-d), x_3(k), x_3(k-1), \dots, x_3(k-d), y_1(k-1), \dots, y_1(k-r_1)), \\ \bar{y}_2 = h_2(x_1(k), x_1(k-1), \dots, x_1(k-d), x_2(k), x_2(k-1), \dots, x_2(k-d), x_3(k), x_3(k-1), \dots, x_3(k-d), y_2(k-1), \dots, y_2(k-r_2)). \end{cases} \quad (2)$$

其中, d 为输入样本长度, r_1 和 r_2 分别为 IV 段黑液残碱及 I 段黑液波美度延迟因子. 由于纸浆洗涤过程是一个大延迟过程, 当任何一个输入变量发生变化时, 洗涤过程残碱和波美度需经较长时间方可趋于稳定^[3]. 根据现场长期的观察和推算, 确定延迟因子分别为: $r_1 = 8, r_2 = 6$.

4.2 两步辨识法(Two-step identification method)

通常, 人们采用大量的稳态数据直接辨识神经网络稳态模型. 它需要不断地对过程施加摄动以获得大量数据构成样本集合. 然而, 频繁地施加摄动会

严重地影响生产,这一般是不允许的.为此,我们选择基于两个神经网络的两步辨识法^[4].其基本思想是:利用过程的动态信息(斜阶跃响应),用一个多层前向神经网络来辨识过程的动态模型,并由此动态模型来产生一个稳态模型的样本集合,然后用另一个多层前向神经网络来逼近过程的稳态特性.结构框图见图 3 和图 4.图中 TDL(tapped delay line)表示按节拍延迟单元.动态神经网络输入可按下式构成:

$$W(k) = [x_1(k), x_1(k-1), \dots, x_1(k-d), x_2(k), x_2(k-1), \dots, x_2(k-d), x_3(k), x_3(k-1), \dots, x_3(k-d), y(k), y(k-1), \dots, y(k-r)]. \quad (3)$$

其中, $W(k)$ 为残碱或波美度输入数据向量,相应地, $y(\cdot)$ 表示 $y_1(\cdot)$ 或 $y_2(\cdot)$.




图 3 神经网络动态模型辨识结构框图
Fig. 3 NN dynamic model identification structure




图 4 稳态神经网络模型辨识结构框图
Fig. 4 NN stationary model identification structure

4.2.1 神经网络动态模型的辨识 (NN dynamic model identification)

残碱和波美度的神经网络动态模型结构参数见表 1, 辨识步骤如下: 1) 权值初始化 (一般采用均匀分布在 $[-1, 1]$ 区间上的随机数进行初始化); 2) 按 r, d 构成输入向量 $W(k)$, 并计算 $\hat{y}(k)$ 及 $e(k) = y(k) - \hat{y}(k)$; 3) 根据所采用的学习算法修正权值; 4) 将 $x_1(k), x_2(k), x_3(k)$ 及 $y(k)$ 移位后, 转到 2); 若 $|e(k)| < \epsilon$ 则结束训练, ϵ 为预先选定的允许误差精度.

表 1 残碱及波美度神经网络动态模型结构参数
Table 1 NN dynamic model parameters of residual soda and Baume degree

	输入层	隐含层	输出层
残碱节点数	24	27	1
波美度节点数	16	19	1
变换函数	$1/(1+e^{-x})$	$1/(1+e^{-x})$	$(1-e^{-x})/(1+e^{-x})$

表 2 残碱及波美度神经网络动态模型训练参数
Table 2 NN dynamic model training parameters of residual soda and Baume degree

网络模型	LR	μ 的初值	μ 的增加率	μ 的减少率	Ep	Err
残碱	0.3	0.001	10	0.1	56	0.002
波美度	0.11	0.001	10	0.1	67	0.002

注: Lk — 学习率; Ep — 学习迭代次数; Err — 学习误差.

为了获得比较精确的数学模型, 分别采用标准 BP 算法、基于动量项和自适应学习率的 BP 算法以及基于 L-M 优化的 BP 算法对神经网络进行训练. 比较发现, 通过基于 L-M 优化的 BP 算法训练出的神经网络动态模型更为理想. 该算法是在标准 BP 算法中采用了 Levenberg-Marguardt 优化方法后, 权值调整率选为

$$\Delta \omega(k) = (J^T(k)J(k) + \mu I)^{-1} J^T(k)e(k).$$

其中, $J(k)$ 为误差对权值微分的 Jacobian 矩阵, $e(k)$ 为误差向量, μ 是受自适应调整的一个标量. 此算法使得学习时间变得更短. 表 2 列出了此算法的神经网络动态模型训练参数, 经过训练所得的学习曲线见图 5, 6, 它们反映了纸浆洗涤过程的动态特性. (实线表示真实曲线, 虚线表示辨识曲线).




图 5 残碱神经网络动态模型学习曲线
Fig. 5 NN dynamic model learning curve of residual soda




图 6 波美度神经网络动态模型学习曲线
Fig. 6 NN dynamic model learning curve of Baume degree

4.2.2 神经网络稳态模型的辨识 (NN stationary model identification)

稳态模型辨识亦采用三层 BP 神经网络. 残碱和波美度的神经网络稳态模型结构参数见表 3.

在 4.2.1 中所建立的残碱和波美度神经网络动态模型的基础上, 不断改变输入变量, 得到相应的稳态数据集 (本系统中各得 150 组数据), 作为稳态

建模的样本集,分别建立残碱和波美度的神经网络稳态模型.将所得的 150 组数据随机的分成两组,前一组 100 个,用于稳态神经网络的训练,后一组 50 个,用于检测训练好的神经网络泛化能力.

表 3 残碱及波美度神经网络稳态模型结构参数

Table 3 NN stationary model parameters of residual soda and Baume degree

	输入层	隐含层	输出层
节点数	3	7	1
变换函数	$1/(1+e^{-s})$	$1/(1+e^{-s})$	$(1-e^{-s})/(1+e^{-s})$

表 4 残碱及波美度神经网络稳态模型训练参数

Table 4 NN stationary model training parameters of residual soda and Baume degree

网络模型	LR	LRI	LRD	MC	Ep	Err
残碱	0.01	0.7	1.05	0.9	80000	0.002
波美度	0.01	0.7	1.05	0.9	19152	0.001

注:LR—学习率;LRI—学习率的增长率;LRD—学习率的减小率;MC—动量项因子;Ep—学习迭代次数;Err—学习误差




图 7 残碱神经网络稳态模型学习曲线
Fig. 7 NN stationary model learning curve of residual soda




图 9 波美度神经网络稳态模型学习曲线
Fig. 9 NN stationary model learning curve of Baume degree

5 双目标优化(Two-objective optimization)

本控制系统的优化目标是:在满足工艺要求的前提下,提高洗涤质量,节能降耗;相对提高首段黑液波美度,维持或进一步降低洗后浆残碱.

5.1 优化问题描述(Optimization problem description)

定义 $E(x_1, x_2, x_3) = x_3$ 为清水消耗量, $Y(x_1, x_2, x_3) = x_1 x_2$ 为生产产量,则双目标优化问题可描述为

对神经网络的训练,也选用了 4.2.1 中采用的三种算法.结果表明通过基于动量项和自适应学习率的 BP 算法训练出的神经网络稳态模型更为理想.与标准的 BP 算法相比,此算法的优点是:在权系数的修正式中引入了前一时刻的负梯度,使学习过程收敛加快.具体表达式为

$$\bar{\omega}(k+1) = \bar{\omega}(k) + \alpha [(1-\eta)D(k) + \eta D(k+1)].$$

其中, $\bar{\omega}(k)$ 为单个的连接权系数或连接权向量(其元素为连接权系数); $D(k)$ 为 k 时刻拟合误差代价函数的负梯度; α 为学习率, $\alpha > 0$; η 为动量项因子, $0 \leq \eta \leq 1$.标准 BP 算法只是按时刻的负梯度修正 $\bar{\omega}(k)$, 没有考虑以前积累的经验,即前一时刻的梯度方向,因此,有时学习过程发生振荡,收敛缓慢.表 4 列出了基于动量项和自适应学习率的 BP 算法神经网络稳态模型训练参数,经过训练所得的学习曲线和泛化曲线见图 7~10(点表示稳态样本集数据,实线为辨识数据或逼近数据连线).可以看出:本 BP 算法的学习效果很好,泛化能力也比较强.




图 8 残碱神经网络稳态模型泛化曲线
Fig. 8 NN stationary model generalizing curve of residual soda




图 10 波美度神经网络稳态模型泛化曲线
Fig. 10 NN stationary model generalizing curve of Baume degree

$$\begin{aligned} \min E(x_1, x_2, x_3) &= x_3, \\ \max Y(x_1, x_2, x_3) &= x_1 x_2, \text{ s. t. } \\ \begin{cases} f_1(x_1, x_2, x_3) \leq F_{1 \max}, \\ F_{2 \min} \leq f_2(x_1, x_2, x_3) \leq F_{2 \max}, \\ X_{1 \min} \leq x_1 \leq X_{1 \max}, \\ X_{2 \min} \leq x_2 \leq X_{2 \max}, \\ X_{3 \min} \leq x_3 \leq X_{3 \max}. \end{cases} \end{aligned} \quad (4)$$

具体求解步骤^[5]为:1)确定两个优化目标的理想值 $\bar{E}$ 和 $\bar{Y}$;2)按各目标与相应理想值的偏差的加权和最小,把上述双目标优化问题转化为单目标优化问题;3)对所得单目标优化问题进行求解,得到最优解 x_1^*, x_2^* 和 x_3^* .于是,式(4)可转化为式(5).其中, β_1, β_2 为加权系数,在 $[0, 1]$ 中取值,且 $\beta_1 + \beta_2 = 1$; C_1 和 C_2 为折算系数,将清水消耗量和产量换算成同一量纲(本文为经济指标,单位为元). $\bar{E}$ 和 $\bar{Y}$ 的取值,原则上可以由单目标优化或经验确定.这里为了使目标函数简洁,以减少在线计算量,在满足工艺要求的前提下,根据经验, $\bar{E}$ 尽可能地取小, $\bar{Y}$ 尽可能地取大,保证 $x_3^* - \bar{E} \geq 0, \bar{Y} - x_1^* x_2^* \geq 0$.

$$\min Z(x_1, x_2, x_3) = \beta_1 C_1(x_3 - \bar{E}) + \beta_2 C_2(\bar{Y} - x_1 x_2),$$

s. t.

$$\begin{cases} g_1(x_1, x_2, x_3) = f_1(x_1, x_2, x_3) - F_{1\max} \leq 0, \\ g_2(x_1, x_2, x_3) = F_{2\min} - f_2(x_1, x_2, x_3) \leq 0, \\ g_3(x_1, x_2, x_3) = f_2(x_1, x_2, x_3) - F_{2\max} \leq 0, \\ g_4(x_1, x_2, x_3) = X_{1\min} - x_1 \leq 0, \\ g_5(x_1, x_2, x_3) = x_1 - X_{1\max} \leq 0, \\ g_6(x_1, x_2, x_3) = X_{2\min} - x_2 \leq 0, \\ g_7(x_1, x_2, x_3) = x_2 - X_{2\max} \leq 0, \\ g_8(x_1, x_2, x_3) = X_{3\min} - x_3 \leq 0, \\ g_9(x_1, x_2, x_3) = x_3 - X_{3\max} \leq 0. \end{cases} \quad (5)$$

5.2 外罚函数法优化步骤(Optimization procedure of external penalty method)

外罚函数法的基本思想^[6]是:由目标函数和约束函数构成(外)罚函数(亦称辅助函数),把原来的有约束问题转化为无约束问题,进而用无约束最优化方法来求解.构造辅助函数: $\Phi(x_1, x_2, x_3, \sigma) = Z(x_1, x_2, x_3) + \sigma \sum_{i=1}^9 [\max\{0, g_i(x_1, x_2, x_3)\}]^2 = Z(x_1, x_2, x_3) + \sigma P(x_1, x_2, x_3)$. 其中, σ 为罚因子,一般为很大的正数; $\sigma P(x_1, x_2, x_3)$ 为罚项.那么,式(5)变成:

$$\begin{cases} \min \Phi(x_1, x_2, x_3, \sigma) = \\ \min \{\beta_1(x_3 - \bar{E}) + \beta_2(\bar{Y} - x_1 x_2) + \\ \sigma \sum_{i=1}^9 [\max\{0, g_i(x_1, x_2, x_3)\}]^2\}, \\ \max\{0, g_i(x_1, x_2, x_3)\} = g_i(x_1, x_2, x_3), \\ g_i(x_1, x_2, x_3) > 0, \\ \max\{0, g_i(x_1, x_2, x_3)\} = 0, \\ g_i(x_1, x_2, x_3) \leq 0, i = 1, 2, \dots, 9. \end{cases} \quad (6)$$

用无约束最优化方法来求解式(6)便能得到式(4)的最优解.优化变量的迭代公式为

$$X(k+1) = X(k) + \lambda \cdot \nabla \Phi(x_1, x_2, x_3, \sigma).$$

其中

$$\nabla \Phi(x_1, x_2, x_3, \sigma) = \frac{\partial}{\partial x_j} \Phi(x_1, x_2, x_3, \sigma), j = 1, 2, 3,$$

λ 为迭代步长,可为一固定常数,也可通过每步优化计算获得.外罚函数法计算步骤为:1)给定初值 $X^{(0)}$ 、初始罚因子 σ_1 、放大系数 $c > 1$ 、允许误差 $\epsilon > 0$,置 $k = 1$;2)以 $X^{(k-1)}$ 为初点求解式(6)无约束问题.设其极小点为 $X^{(k)}$;3)若 $\sigma_k P(x_1, x_2, x_3) < \epsilon$,则停止计算,得到最优解 $X^{(k)}$;否则,令 $\sigma_{k+1} = c\sigma_k$,置 $k = k + 1$,返回 2).

5.3 优化结果(Optimization results)

取 $\beta_1 = \beta_2 = 0.5$;根据工艺指标,取 $F_{1\max} = 2.5, F_{2\min} = 7.0, F_{2\max} = 9.0, X_{1\min} = 2.0, X_{1\max} = 2.4, X_{2\min} = 100, X_{2\max} = 135, X_{3\min} = 25, X_{3\max} = 35$.对由 4.2.1 中产生的三组稳态数据,用 4.2.2 中训练出的三种神经网络稳态模型,进行双目标优化计算,得到 9 组优化结果.不同算法所得到的优化结果大致相同,这间接说明了本文中采用的建模方法的可行性和有效性.其中,由基于 L-M 优化的 BP 算法所产生的稳态数据用基于动量项和自适应学习率的 BP 算法训练出的神经网络稳态模型进行优化的结果见表 5.可以看出:优化后,进浆浓度和进浆流量都达到了允许上限值,清水流量却靠近允许下限值,说明优化后产量提高了;清水消耗量的增加是约束条件限制的结果,这是为保证洗涤质量所必须的.

表 5 双目标优化结果

Table 5 The results of two-objective optimization

优化变量	初始值	步长 λ	罚因子 σ	放大系数 c	迭代次数	优化结果
进浆浓度	2.2					2.4
进浆流量	117.5	450	1.0	4	230	135
清水流量	27.6					29
生产产量						311.94(吨/小时)

6 结束语(Conclusion)

这套控制系统已于 1999 年在山东某纸厂成功投运,2000 年 9 月又在河南一家纸厂试投,目前正处在试运中.图 11 和图 12 给出了优化后在山东这家纸厂 20 小时的运行曲线与优化前的运行结果比较(虚线代表优化前,实线代表优化后).可以看出:优化前,残碱及波美度基本上都能满足工艺要求(残

碱不高于 2.5,波美度波动范围在 7.0 到 9.0 之间)。这是优化前浓度控制子系统、液位控制子系统、流量控制子系统和温度控制子系统控制的控制结果。优化后,曲线波动明显变小,且残碱进一步下降,波美度再度提高。这恰恰体现了优化控制的作用,说明了本优化控制子系统能够平衡残碱与波美度之间的矛盾,达到了预期目的。




图 11 优化前后残碱对比曲线

Fig. 11 The curves comparison of residual soda before & after optimization




图 12 优化前后波美度对比曲线

Fig. 12 The curves comparison of Baume degree before & after optimization

参考文献(References)

[1] Zheng E R, Zhao X M, Wang M X, et al. Modeling pulp washing

process based on neural network (I) [J]. Control and Instrument in Chemical Industry, 2000,27(4):6-9

- [2] Yang C J, Sun Y X, Bao B L. The present and future of the pulp washing process control [J]. China Paper, 1998,19(3):25-28
- [3] Rudd J B, DeGroot D L. Control system for controlling a pulp washing system using neural network controller [P]. U. S. Patent: 5282131,1994
- [4] Wan B W, Huang Z L. Computer on-Line Optimization Control of Large-Scale Industrial Processes [M]. Beijing: Science Press,1998
- [5] Shen J Z. Process System Optimization [M]. Beijing: Mechanical Industry Press,1990
- [6] Chen B L. Optimization Theory and Algorithms [M]. Beijing: Tsinghua University Press,1989

本文作者简介

汤 伟 1971 年生,1997 年获西北轻工业学院轻工机械专业工学硕士学位。现为上海交通大学控制理论与控制工程专业博士生。主要研究方向:鲁棒控制,时滞过程控制及应用。 Email: wtangqp6@263.net

施颂椒 1933 年生,上海交通大学自动化系教授,博士生导师。主要研究方向为:鲁棒控制,自适应控制。

王孟效 1941 年生,1967 年毕业于上海华东师范大学物理系。现为西北轻工业学院自动控制系主任,教授。主要研究领域为造纸过程自动化系统的开发与应用等。

赵小梅 1974 年生,1999 年获西北轻工业学院轻工机械专业工学硕士学位。现为浙江大学工业控制研究所工业自动化专业博士生。感兴趣的领域:神经网络和智能控制等。

郑恩让 1962 年生,1988 年获重庆大学自动化专业工学硕士学位。现为西北轻工业学院自动化系副教授。主要研究方向:神经网络,计算机仿真和智能控制。