文章编号: 1004-0609(2007)07-1201-06

基于核偏最小二乘法的动态预测模型在 铜转炉吹炼中的应用

宋海鹰,桂卫华,阳春华,彭小奇

(中南大学 信息科学与工程学院, 长沙 410083)

摘 要:为实现铜转炉吹炼过程中的关键操作参数的准确预测,构造一种基于核偏最小二乘法的动态预测模型,并提出一种适用于动态建模的在线式异常样本剔除方法。该动态预测模型使用滑动窗方法不断更新建模数据,再利用核偏最小二乘法对动态模型的参数进行辨识,最后根据反馈的前次计算误差对本次预测值进行修正。仿真研究结果表明:该动态预估模型具有较好的泛化能力和较强的鲁棒性,并具有较好预测精度(风量预测的相对均方根误差小于 10%,氧量预测的相对均方根误差小于 19%)。目前,该预测模型被用于某转炉的吹炼辅助决策系统中。
 关键词:动态预测模型;在线式异常样本剔除;核偏最小二乘法;关键操作量预测;铜转炉吹炼
 中图分类号: TP 18 文献标识码: A

Application of dynamical prediction model based on kernel partial least squares for copper converting

SONG Hai-ying, GUI Wei-hua, YANG Chun-hua, PENG Xiao-qi

(School of Information Science and Engineering, Central South University, Changsha 410083, China)

Abstract: In order to predict accurately the key operational parameters in copper converting process, a dynamical prediction model based on kernel partial least squares was constructed, and a method of online eliminating abnormal samples for dynamical model was presented. Firstly, moving widow method was utilized to update samples continuously in dynamical prediction model. Then, kernel partial least squares was used to identify parameters of dynamical model. Lastly, the prediction values were modified according to the last feedback computing errors. The simulation result shows that this dynamical prediction model has the performances like, better generalization, stronger robust, and preferable accuracy (the relative root mean square error of air is lower than 10%, and the relative root mean square error of oxygen is lower than 19%). Now, the prediction model is applied in the assistant decision-making system for a copper converter.

Key words: dynamical prediction model; online eliminating abnormal samples; kernel partial least squares method; copper converting

现代铜的火法生产中,闪速熔炼完成了铜与大部 分铁的分离获得铜锍,然后在铜转炉中进行铜锍吹炼, 从而进一步除去铜锍中的铁、硫和其它杂质,获得纯 度为98%以上的粗铜。铜锍的吹炼过程绝大多数是在 卧式侧吹(Peirce-Smith, PS)转炉内进行的。吹炼过程为

间歇式的周期性作业,整个过程分为2个阶段:造渣 期和造铜期。

目前,铜转炉的生产方式仍为人工操作方式,生 产质量依赖于工人的技术水平。因此,对吹炼过程中 操作参数的准确预报能使相关操作人员事先知道操作

收稿日期: 2006-10-17; 修订日期: 2007-04-27

基金项目:国家重点基础研究发展规划资助项目(2002cb312200);国家自然科学基金重点资助项目(60634020;60574030;50374079);博士点基金 (20050533016)

通讯作者: 宋海鹰, 博士研究生; 电话: 0731-8830394; E-mail: songhaiying1975@163.com

(2)

的结果,有利于实现流程工业过程的预测控制、保持 工况稳定。由此可见,实现铜 PS 转炉吹炼过程中关 键操作参数一风量和氧量的预测将日趋重要。

神经网络建模方法是目前最常用的一种稳态操作 条件下基于生产数据的建模方法^[1-5],例如为优化铜锍 生产,彭小奇等^[6]采用 BP 神经网络对 PS 转炉造铜期 的氧量进行了预测,取得一定效果。但传统的神经网 络建模方法都是立足于样本数目足够多的前提下,所 提出的各种预测方法只有在样本数趋向于无穷大时其 性能才有理论上的保证。而在多数实际情况中,样本 数目通常是有限的,这使得神经网络方法难以取得理 想的效果。因此,小样本预测一直是学者们研究的热 点问题。

支持向量机作为一种常用的小样本统计建模方法,目前正得到越来越多的应用^[7-9],但由于这一建模方法需要事先对折中系数(罚系数)和核参数进行优化选择,因此,将其作为实时动态模型应用颇为不便。 而基于核偏最小二乘回归的统计建模法,则是另一种 有效的小样本非线性建模方法^[10-12]。

由于造渣期是整个吹炼过程的关键环节,造渣的 好坏直接决定了吹炼最终产品—粗铜的质量,因此, 铜转炉造渣期中关键操作量—氧量和风量的预测问 题,是一个具有重要研究价值的实际生产问题。造渣 期被分为造渣 S₁期和造渣 S₂期,其中造渣 S₂期是造 渣期的最后一个阶段。因此,能否准确预测造渣 S₂ 期风量和氧量是优化整个吹炼过程的关键。

为满足工业生产中实现对造渣 S₂ 期风量和氧量 的实时预估,本文作者首先建立了一种基于核偏最小 二乘回归法的动态预测模型,并提出了一种配合此动 态模型使用的异常数据在线剔除方法,最后利用该模 型对铜转炉吹炼造渣 S₂ 期所需总风量和总氧量进行 预测。

基于核偏最小二乘回归的动态预 测模型

1.1 动态模型的结构

工业过程通常都很复杂,外界对过程的种种扰动 难以把握,因此,仅依靠工业过程的机理很难建立准 确的数学模型。但是,在生产设备运行稳定、工作条 件相似时,扰动的变化范围有限。因此,可以通过历 史数据样本,得出一个过程的预估模型。以铜转炉吹 炼风、氧量操作参数的预报为例,可以认为当前的输 出参数值由邻近时段内的输入参数值所决定。因此, 在构造非线性动态预测模型时,*k*+1时刻的输出可以表 示为前n个输入的函数(FIR模型),公式表示如下:

$$y(k+1) = f(x(k), \dots, x(k-n+1)) + e$$
 (1)

式中 *x*(*k*)、*y*(*k*)分别为工业过程的第*k*次(或第*k*班、 第*k*时刻)输入向量和输出向量,*n*为输入的影响延迟 步数(阶数),*f*表示某种函数关系,而*e*是由于扰动引 起的误差。

根据实际生产情况,模型的系数需要及时调整, 以跟踪生产过程的趋势,因此,本文中作者进一步采 用了滑动窗技术,根据及时更新的检测数据,建立了 动态的转炉吹炼风量和氧量的预估模型。滑动窗口中 的样本数据排列成一个二维矩阵,其中行的维数为窗 口内各变量分别在 k、k-1、k-2 处所取样本值依次排 列所成序列的尺度;而窗口中的各列,则是自变量在 各时刻值所组成的数据序列。本文中将利用第 k、k-1、 k-2 时刻的自变量数据与第 k+1 时刻的因变量,建立 的动态模型如下所示:

式中

 $Y = [y_1(k+1)\cdots y_m(k+1)] \quad (y_i \in \mathbf{R}^N)$

 $X = [x_1(k), x_1(k-1), x_1(k-2), \cdots, x_l(k), x_l(k-1), x_l(k-2)]$ ($x_i \in \mathbb{R}^N$)

B为模型的参数向量,将由核偏最小二乘法辨识得到。

1.2 基于核偏最小二乘的参数辨识

由式(2)可见,动态模型的参数辨识问题是建模的 关键。一般而言,最小二乘法是最常采用的参数辨识 方法,但这种辨识方法在辨识列维数远大于行维数的 参数矩阵时,特别是当*X*中的变量存在严重的多重相 关性时,效果不好。

而由 Wold 等^[13]提出的偏最小二乘回归法(Partial Least Square Regression,PLS)作为第二代最小二乘回 归技术,可以较好地解决消除自变量间的线性相关关 系,因此可以作为解决不稳定估计问题的有效方法。 该方法通过最大化从自变量矩阵和因变量矩阵中提取 自变量矩阵主成分*t*和因变量矩阵主成分*u*间的协方 差,找到能最大包含数据矩阵*X*和*Y*的信息的主成分, 继而将原数据空间中的回归问题转化对主成分*t*和*u* 的双线性回归问题。Rosipal 等^[14-15]在其基础上进一步 提出了核偏最小二乘回归法(Kernel PLS),从而使偏最 小二乘回归法能用于解决非线性回归的 问题。

设样本空间 X 在特征空间中的映射为 $\varphi(X)$, 令 $K^{0}=\varphi(X)\varphi(X)^{T}$,并设 M 为预测设定的主元数, Kernel PLS 的算法可表示如下^[16]。 1) 对 K⁰进行对中处理后得:

$$\boldsymbol{K}^{1} = \left(\boldsymbol{I} - \frac{1}{N}\boldsymbol{I}\boldsymbol{I}^{\mathrm{T}}\right)\boldsymbol{K}^{0}\left(\boldsymbol{I} - \frac{1}{N}\boldsymbol{I}\boldsymbol{I}^{\mathrm{T}}\right)$$
(3)

式中 *I*表示 *N*×*N* 维单位阵, 而 *I* 为 *N* 维全 1 列向量。

2) For *n*=1 to *M*

$$t^{n} = K^{n} y^{n}, t^{n} = t^{n} / \left\| t^{n} \right\|$$
$$K^{n+1} = (I - t^{n} t^{n^{T}}) K^{n} (I - t^{n} t^{n^{T}})$$
$$y^{n+1} = y^{n} - t^{n} t^{n^{T}} y^{n}, y^{n+1} = y^{n+1} / \left\| y^{n+1} \right\|$$

式中 N表示样本数。

3) 找出 *M* 个主元后,计算得到的回归系数向量 如下:

$$\boldsymbol{\alpha} = \boldsymbol{Y}(\boldsymbol{T}^{\mathrm{T}}\boldsymbol{K}^{\mathrm{1}^{\mathrm{T}}}\boldsymbol{Y})^{-1}\boldsymbol{T}^{\mathrm{T}}\boldsymbol{y}$$
(4)

式 中 $Y = [\cdots y^n \cdots]_{N \times M}$, $T = [\cdots t^n \cdots]_{N \times M}$, $\boldsymbol{\alpha} = [\alpha_1, \cdots, \alpha_i, \alpha_N]^{\mathrm{T}}$ 。

在对核矩阵进行对中处理后,进行回归时,将不 出现偏置量参数,于是预测公式可写为:

$$f(\mathbf{x}) = \sum_{i=1}^{N} a_i K(\mathbf{x}, \mathbf{x}_i)$$
(5)

利用式(5)作预测时,式(5)中的核矩阵表示为:

$$\boldsymbol{K}^{\text{test}} = (\boldsymbol{K}^{\text{test}} - \frac{1}{N}\boldsymbol{1}\boldsymbol{1}^{\mathrm{T}}\boldsymbol{K}^{\text{train}})(\boldsymbol{I} - \frac{1}{N}\boldsymbol{1}\boldsymbol{1}^{\mathrm{T}})$$
(6)

式中 **K**^{train} 表示通过训练由算法步骤 2 建立的核矩 阵, **K**^{test}表示预测时式(5)中的核矩阵。

1.3 数据的预处理

建模过程中,为建立较稳定模型结构,需要剔除 样本中的异常数据,增加模型抗干扰能力,而目前剔 除异常样本的算法只适用于离线建模。常用的用于离 线剔除异常样本的 Chauvenet 和 Gubbs 公式,可表示 为:

$$|x_i - \bar{x}| \ge c \cdot \sigma \tag{7}$$

其中 x_i 为第i次的采样值, \bar{x} 是样本的平均值, σ 是 样本的方差, 而c则为调整参数(设为常数)。

为适应建立动态模型的需要,本文作者提出一种 改进型在线剔除异常样本的方法,首先对式(7)中的样 本平均值和样本方差分别采用下式进行确定^[17]:

$$\overline{\boldsymbol{x}}_{k+1} = \frac{N-1}{N} \overline{\boldsymbol{x}}_k + \frac{1}{N} \boldsymbol{x}_{k+1}$$
(8)

$$\sigma_{k+1}^2 = \frac{N-2}{N-1}\sigma_k^2 + \frac{1}{N-1}(x_{k+1} - \overline{x}_{k+1})^2$$
(9)

考虑到生产过程中操作情况的变化,调整参数也 应该为变量,因此,论文中提出根据样本的波动对调 整参数进行自适应调整,算法如下:

 据滑动窗内的每一变量的最大值和最小值,以及平均值和方差;并根据式(7)分别计算其对应的调整 参数 c₁和 c₂。

采用 Chauvenet 公式计算得到系数 c₀₁,同时采用 Gubbs 公式计算得到系数 c₀₂,通常 c₀₁>c₀₂。

3) 取出 *c*₁和 *c*₂中的最小值,将其与 *c*₀₁和 *c*₀₂做 比较,从三者中选出中间值作为调整参数 *c*。

本论文中在采用在线式异常样本剔除方法后,对 输入、输入矩阵进一步进行了自标准化处理,将原始 数据转换成均值为0,标准偏差为1的新数据。

1.4 预测模型的反馈校正

模型的校正,从理论上可以分为模型结构校正和 模型系数校正2种,基于滑动窗的模型修正方法属于 后者。实际应用时,还需引入反馈修正项,补偿由于 操作参数波动过大造成的计算偏差,其修正公式如下:

$$\widetilde{Y}(k+1) = \widehat{Y}(k+1) + \Delta Y(k+1)$$
(10)

$$\Delta Y(k+1) = \omega \times \Delta Y_0(k+1) + (1-\omega) \times \Delta Y(k)$$
(11)

$$\Delta Y_0(k+1) = Y(k) - \Delta \hat{Y}(k) \tag{12}$$

其中 ω 为 0.7, \tilde{Y} 表示校正后的值, \hat{Y} 表示动态模型的计算值, Y表示实际值。

2 仿真研究

本论文中利用上述建模方法,针对某厂的 5 号 (Peirce-Smith)铜转炉,利用其 117 炉连续生产数据进 行仿真研究。

2.1 模型的输入/输出变量选择

对铜转炉造渣期的吹炼机理进行分析可知,影响 造渣 S₂期风量和氧量的变量包括:造渣 S₁期和 S₂期 的铜硫添加量(x_1, x_2)、造渣期熔剂添加量(x_3)、造渣期 多种冷料的添加量(x_4, x_5)、造渣 S₁期的渣量(x_6)、造 渣 S₁期的渣成分(x_7)、造渣 S₁期所用的时间(x_8)、造

1203

渣 S_1 期所用的风量(x_9)和造渣 S_1 期所用的氧量(x_{10})。

综上分析,选择上述各变量在 k、k-1、k-2 炉次 的值组成输入向量,对输出变量—造渣 S₂期所用的总 风量和总氧量[y₁(k), y₂(k)]建立动态预估模型。

2.2 输入/输出变量间多重相关性的分析

由于模型的输入变量间,以及输入和输出变量间 存在严重的多重相关性,为分析其间的相关程度,根 据历史数据计算自变量和因变量间的相关系数平方 值,计算结果如表1所示。

由表 1 可见,不仅各自变量向量与因变量向量间 有较强相关性,而且各自变量向量间也有较强的相关 性。例如,造渣 S₂期总风量与造渣 S₁期铜锍加入量、 冷料添加量之间存在较高的相关系数,这表示加入的 铜锍、冷料越多,S₂期所需的总风量也越多。因此, 对于这些具有较强相关性的向量,偏最小二乘法是最 适合的参数辨识方法。

2.3 预测模型中主元的累计解释能力

论文选择 t1、t2、t3 作为偏最小二乘回归的主元。

表1 输入/输出变量间的相关系数

由 Kernel PLS 的算法可知, *X* 的主元向量 *T* 决定了数 据矩阵 *X* 和 *Y* 的回归精度, 即向量 *T* 中的元素对自变 量和因变量的解释性能, 这可用累计解释能力表示。为 研究这一关系, 文中分析了第一个滑动窗内 *X* 的数据 矩阵的主元 *t*₁、 *t*₂、 *t*₃、 *t*₄ 和数据矩阵 *X* 和 *Y* 间的关系。

首先利用偏最小二乘方法依次求出X数据矩阵的 4个主成分 t₁、t₂、t₃、t₄,再计算出这4个主成分 t₁、 t₂、t₃、t₄对自变量和因变量的累计解释能力 R_d (即所 有主元与各变量间相关系数平方的累积值),其结果如 表 2 所示。由表 2 可见,t₃对各自变量和因变量的累 计解释能力均达到 1.0 以上,因此,对 t₁、t₂、t₃进行 回归可满足计算精度。

2.4 预测结果分析

论文中针对某厂铜转炉数据进行仿真研究,利用 历史报表数据,建立具有跟踪生产趋势能力的吹炼风/ 氧量动态预估模型,预测结果与实际值对比如图1和 2所示。

由图1和2可见,经补偿修正后的预测结果与实际数据基本吻合,能准确预测关键操作量的变化趋势。 但是,部分预测结果也出现较大波动,使得预测准确

r	\boldsymbol{x}_1	\boldsymbol{x}_2	\boldsymbol{x}_3	\boldsymbol{x}_4	\boldsymbol{x}_5	\boldsymbol{x}_6	\boldsymbol{x}_7	x_8	x_9	x_{10}	y_1	y_2
\boldsymbol{x}_1	1.000 0	0.111 1	0.562 2	0.308 7	0.703 8	0.720 3	0.700 9	0.045 9	0.044 5	0.193 4	0.278 6	0.033 6
x_2		1.000 0	0.155 4	0.111 1	0.017 6	0.091 3	0.004 6	0.012 9	0.965 5	0.964 9	0.002 9	0.033 6
x_3			1.000 0	0.007 2	0.124 8	0.089 5	0.074 1	0.235 6	0.047 1	0.138 7	0.027 3	0.262 8
x_4				1.000 0	0.438 6	0.821 2	0.700 9	0.756 0	0.146 2	0.251 7	0.844 9	0.697 7
x_5					1.000 0	0.764 8	0.925 6	0.331 7	0.040 4	0.000 8	0.661 6	0.330 4
x_6						1.000 0	0.940 1	0.467 3	0.074 0	0.218 7	0.762 1	0.424 5
\boldsymbol{x}_7							1.000 0	0.490 8	0.000 8	0.058 5	0.814 3	0.468 7
x_8								1.000 0	0.000 1	0.003 5	0.882 5	0.995 0
x_9									1.000 0	0.941 9	0.000 1	0.006 5
x_{10}										1.000 0	0.017 8	0.000 1

表2 累计解释能力

 Table 2
 Cumulative explanatory ability

R_d	\boldsymbol{x}_1	\boldsymbol{x}_2	<i>x</i> ₃	x_4	x_5	x_6	\boldsymbol{x}_7	x_8	x 9	x_{10}	\boldsymbol{y}_1	y_2
t_1	0.252 3	0.000 3	0.038 3	0.876 4	0.608 4	0.752 5	0.782 3	0.906 2	0.001 1	0.028 8	0.996 2	0.886 4
t ₂	0.979 1	0.056 0	0.971 9	0.878 0	0.931 8	0.952 9	0.999 2	0.999 3	0.004 5	0.093 6	0.997 7	0.991 2
t ₃	1.252 3	1.000 3	1.038 3	1.876 4	1.608 4	1.752 5	1.782 3	1.906 2	1.001 1	1.028 8	1.996 2	1.886 4
t ₄	3.436 6	1.214 6	2.424 3	4.149 2	3.873 3	4.336 4	4.376 3	3.962 5	1.101 7	1.428 3	4.427 8	3.887 6



图1 修正后的氧量预测值与实际值的对比

Fig.1 Predicting results of used oxygen vs practical used oxygen



图 2 修正后风量预测值与实际值的对比 Fig.2 Predicting results of used air vs practical used air

度下降。这是由于建模数据本身为人工操作条件下的 经验数据,在使用波动较大的数据建模时,辨识得到 的动态模型的回归系数的计算误差也随之增大,同时 由于反馈补偿的效果,使得前次预测结果影响到本次 预测结果。综上分析,当用于建模的数据出现较大波 动时,预测值将出现较大波动。

为评价预测模型的性能,本文中分别使用了最大相对误差、均方根误差(*R*_{MSE})和相对均方根误差(*R*_{RMSE}) 对模型的预测准确性和跟踪变化趋势的能力进行分 析,其公式如下^[15]:

$$E_{\max} = \max(\frac{y_i - \hat{y}_i}{y_i}) \tag{13}$$

$$R_{\rm MSE} = \sqrt{\frac{1}{l} \sum_{i=1}^{l} (y_i - \hat{y}_i)^2}$$
(14)

$$R_{\rm RMSE} = \sqrt{\frac{1}{l} \sum_{i=1}^{l} (\frac{y_i - \hat{y}_i}{y_i})^2}$$
(15)

式中 y_i 为实际数据向量中的第 i 个数据, \hat{y}_i 为预测 所得数据向量中的第 i 个数据。表 3 中列出了采用误 差反馈修正前后的相对误差的对比值。

表3 预测结果的误差分析

Table 3 Error analysis of predicting resu	lts	
--	-----	--

$E_{\rm max}$ /%	$R_{\rm MSE}/{ m Nm}^3$	R _{RMSE} /%
18.8	26.5	10.8
25.5	15.3	19.1

由表 3 可见,预测结果的相对均方根误差分别为 10.8%和 19.1%,处于工厂操作量的允许误差范围内, 因此,预测结果可作为现场生产的指导信息。

3 结论

 所建立的铜转炉吹炼风/氧量预估模型具有所 需建模样本少、模型泛化能力强的特点,当变量之间 存在高度相关性时,利用偏最小二乘回归法辨识动态 模型参数具有良好的解释性,符合实际情况。

2)提出的动态预测模型,能准确跟踪实际工况的 波动特征,预测结果表明,这种建模方法具有学习能 力强、泛化能力好及抗噪性强的优点,可以较好地跟 踪具有较大波动幅度的过程变化趋势,在过程工业的 优化和控制领域具有巨大的应用价值。

REFERENCES

 [1] 唐朝晖,桂卫华,吴 敏,陈晓方.基于神经网络和灰色理论 的密闭鼓风炉透气性预测模型[J].中国有色金属学报,2003, 13(5):1306-1310.

TANG Zhao-hui, GUI Wei-hua, WU Min, CHEN Xiao-fang. Predicative model based on neural network and gray theory for imperial blast furnace breathing capacity[J]. The Chinese Journal of Nonferrous Metals, 2003, 13(5): 1306–1310.

[2] HAO Xiao-jing, ZHENG Peng, XIE Zhi. A predictive modeling for blast furnace by integrating neural network with partial least squares regression[C]//IEEE International Conference on Industrial Technology. United States: Institute of Electrical and Electronics Engineers Inc, Piscataway, NJ 08855-1331, 2004: 1162–1167.

1205

- [3] 高宪文,张傲岸,魏庆来. 基于神经网络的钢包精炼终点预 报[J]. 东北大学学报, 2005, 26(8): 726-728.
 GAO Xian-wen, ZHANG Ao-an, WEI Qing-lai .Neural network based prediction of endpoint in ladle refining process[J].
 Northeastern University(Natural Science), 2005, 26(8): 726-728.
- [4] Roy N K, Potter W D, Landau D P. Polymer property prediction and optimization using neural networks[J]. IEEE Transactions on Neural Networks, 2006, 17(4): 1001–1014.
- [5] 邓长辉, 王 妹, 王福利, 毛志忠, 王嘉铮. 真空感应炉终点 碳含量预报[J]. 控制与决策, 2006, 21(2): 210-212.
 DENG Chang-hui, WANG Shu, WANG Fu-li, MAO Zhi-zhong, WANG Jia-zheng. End-point carbon content prediction based on RBF neural network[J]. Control and Decision, 2006, 21(2): 210-212.
- [6] 彭小奇,胡志坤,梅 炽,胡 军,姚峻峰. 炼铜转炉吹炼终 点的神经网络和自适应残差补偿组合预报模型[J]. 控制理论 与应用, 2002, 19(1): 149-151.
 PENG Xiao-qi, HU Zhi-kun, MEI Chi, HU Jun, YAO Jun-feng. Converting furnace endpoint prediction model based on neural network and adaptive error compensation[J]. Control Theory and Applications, 2002, 19(1): 149-151.
- [7] 杨金芳, 翟永杰, 王东风, 徐大平. 基于支持向量回归的时间 序列预测[J]. 中国电机工程学报, 2005, 25(17): 110-114. YANG Jin-fang, ZHAI Yong-jie, WANG Dong-feng, XU Da-ping. Time series prediction based on support vector regression[J]. Proceedings of the Chinese Society of Electrical Engineering, 2005, 25(17): 110-114.
- [8] 桂卫华,李永刚,阳春华,陈志盛.基于改进聚类算法的分布 式 SVM 及其应用[J]. 控制与决策, 2004, 19(8): 852-856.
 GUI Wei-hua, LI Yong-gang, YANG Chun-hua, CHEN Zhi-sheng. Distributed SVM based on improved clustering algorithm and its application[J]. Control and Decision, 2004, 19(8): 852-856.
- [9] LI Hai-sheng, ZHU Xue-feng. Application of support vector machine method in prediction of kappa number of kraft pulping

process[C]//Proceedings of the World Congress on Intelligent Control and Automation (WCICA), v 4, WCICA 2004. Fifth World Congress on Intelligent Control and Automation, Conference Proceedings. United States: Institute of Electrical and Electronics Engineers Inc, Piscataway, 2004: 3325–3330.

- [10] Duchesne C, MacGregor J F. Multivariate analysis and optimization of process variable trajectory for batch processes[J]. Chemometrics and Intelligent Laboratory Systems, 2000, 51(1): 125–137.
- [11] Baffi G, Martin E B, Morris A J. Non-linear dynamic projection to latent structures modeling[J]. Chemometrics and Intelligent Laboratory System, 2000, 52(1): 5–22.
- [12] Kim K, Lee J M, Lee I B. A novel multivariate regression approach based on kernel partial least squares with orthogonal signal correction[J]. Chemometrics and Intelligent Laboratory System, 2005, 79(1/2): 22–30.
- [13] Wold S, Sjostrom M, Eriksson L. PLS-regression: A basic tool of chemometrics, Chemometrics and Intelligent Laboratory Systems, 2001, 58(2): 109–130.
- [14] Rosipal R. Kernel partial least squares for nonlinear regression and discrimination[J]. Neural Network World, 2003, 13(3): 291–300.
- [15] Rosipal R, Trejo L J. Kernel partial least squares regression in reproducing kernel Hilbert space[J].Machine Learning Research.2002, 2(2): 97–123.
- [16] Bennett K P, Embrechts M J. An optimization perspective on kernel partial least squares[C]//Proceeding of the NATO Advanced Study Institute on Learning Theory and Practice. Amsterdam: IOS Press, 2003: 2–21.
- [17] MU Sheng-jing, ZENG Ying-zhi, LIU Rui-lan. Online dual updating with recursive PLS model and its application in predicting crystal size of purified terephthalic acid(PTA) process[J]. Process Control, 2002, 16(6): 557–566.

(编辑 李向群)