

文章编号: 1000-6788(2009)09-0153-07

## 基于核主元分析与多支持向量机的监控诊断方法及其应用

蒋少华<sup>1,2</sup>, 桂卫华<sup>1</sup>, 阳春华<sup>1</sup>, 唐朝晖<sup>1</sup>

(1. 中南大学 信息科学与工程学院, 长沙 410083; 2. 韶关学院 计算机科学学院, 韶关 512024)

**摘要** 为保证密闭鼓风炉冶炼过程的正常运行, 构造了一种基于核主元分析 (KPCA) 和多支持向量机 (MSVM) 的监控模型. 该监控模型首先用核主元分析方法对过程数据进行特征提取, 然后将代表过程特征的核主元送入到多支持向量机分类器中进行故障诊断与分类. 仿真研究显示, 该监控模型具有较好的泛化能力, 能有效地应用于鼓风炉的监控诊断, 可用于鼓风炉熔炼过程的现场操作指导.

**关键词** 核主元分析; 多支持向量机; 过程监控诊断; 密闭鼓风炉

**中图分类号** TP277

**文献标志码** A

## Monitoring model based on kernel principal component analysis and multiple support vector machines and its application

JIANG Shao-hua<sup>1,2</sup>, GUI Wei-hua<sup>1</sup>, YANG Chun-hua<sup>1</sup>, TANG Zhao-hui<sup>1</sup>

(1. School of Information Science and Engineering, Central South University, Changsha 410083, China; 2. School of Computer Science, Shaoguan University, Shaoguan 512024, China)

**Abstract** In order to keep the imperial smelting furnace (ISF) working smoothly, a dynamical monitoring model based on kernel principal component analysis (KPCA) and multiple support vector machine (MSVM) is constructed. Firstly, the KPCA approach is adopted to extract the feature, and then the SVM multi-class classifiers are used for classification with the input of the feature. The simulation research shows that this dynamical monitoring model has the performances like, better generalization, stronger robust, and preferable monitoring result. Now, the monitoring model is applied in the assistant decision-making system of a imperial smelting furnace.

**Keywords** kernel principal component analysis; multiple support vector machine; process monitoring and fault diagnosis; imperial smelting furnace

### 1 引言

密闭鼓风炉炼铅锌技术 (Imperial smelting process, 简称 ISP) 由英国帝国熔炼公司于上世纪五十年代发明, 是近代火法冶炼铅锌的先进方法之一. 它主要包括铅锌烧结过程和密闭鼓风炉熔炼过程两部分, 将浮选的铅锌混合精矿烧结后, 经破碎筛分将合格烧结块送入密闭鼓风炉, 在高温和强还原气氛中通过氧化锌和氧化铅的还原反应, 并根据铅、锌的熔沸点不同, 同时生产出铅锌两种金属.

**收稿日期:** 2008-07-21

**资助项目:** 国家自然科学基金重点基金 (60634020); 国家自然科学基金 (60574030); 博士点基金 (20050533016)

**作者简介:** 蒋少华 (1966-), 女, 广西桂平人, 博士研究生, 高级工程师, 主要研究方向为智能控制、复杂过程故障诊断等.

铅锌密闭鼓风炉冶炼过程的高度复杂性,使得对于它的故障诊断,至今还没有十分行之有效的方法.由于冶金界对铅锌密闭鼓风炉内部的研究远远不如对炼铁高炉的研究透彻,对其操作条件与过程参数之间、过程参数与生产目标之间以及炉内各反应进程之间极为复杂的制约关系没有可靠的研究结果能够加以利用,而最终一个故障的形成往往是众多因素造成的结果,各因素之间既有十分复杂的联系,各自对最终故障贡献的权重也十分模糊,因此无法用精确的状态模型进行表示.随着人工神经网络在过程系统建模、故障诊断以及在线优化等方面应用广泛,基于人工神经网络等的密闭鼓风炉的监控诊断方法已有相关研究<sup>[1-2]</sup>.但上述方法在处理非线性问题以及泛化能力方面仍存在不足.目前比较有效的监控方法是采用基于数据驱动的模式识别方法<sup>[3]</sup>.这一方法要求收集正常操作条件下的,以及在各种故障状态下的历史数据.其诊断步骤包括特征提取 (Feature extraction) 和模式识别两步,目标是提取出可以明确识别的某一类型的特征,并在此基础上最优地对采集到的样本进行分类.

特征提取方法有多种,如较常用的就是主元分析 (PCA) 方法.它依据输入变量的线性变换,由输入变量互相关矩阵的主要特征值的大小来确定坐标变换和变量压缩来提取主元特征.然而 PCA 是一种线性算法,只考虑二阶统计特性,只能提取数据中的线性关系.当信号特征存在着大量非线性关系时,已经不能满足要求<sup>[4]</sup>.核主元分析方法 KPCA 是一种新的非线性特征提取方法,它通过某种事先选择的非线性映射将输入矢量映射到一个高维特征空间,使输入矢量具有更好的可分性,然后对高维空间中的映射数据做线性主元分析,从而得到数据的非线性主元<sup>[5-6]</sup>.该方法在实施过程中没有复杂的非线性运算,可调参数少.支持向量机 (SVM) 在小样本下具有良好的学习能力,在各领域已取得广泛的应用<sup>[7]</sup>,由于 KPCA 和 SVM 结合能充分发挥各自的优势,提高故障诊断模型的实时性,KPCA-SVC 方法已用于化工过程故障诊断<sup>[8]</sup>.为此,作者采用了改进的 KPCA-MSVM 方法对炉子熔炼过程进行监控.仿真和工业应用结果表明,所提出的模型能很好实现密闭鼓风炉炉况监控,并能使铅锌产量得到显著的提高.

## 2 核主元分析

设有  $n$  维的  $l$  个样本数据为:  $x_1, x_2, \dots, x_l \in \mathbf{R}^n$ . 首先用一非线性映射  $\psi(\cdot)$  把输入数据从原空间  $\mathbf{R}^n$  映射到高维特征空间有  $\psi(x) = (\varphi(x_1), \varphi(x_2), \dots, \varphi(x_l))$ , 然后在这个高维特征空间进行线性主元分析. 特征空间中映射数据的协方差为:

$$C = \frac{1}{l} \sum_{j=1}^l \varphi(x_j) \varphi(x_j)^T \quad (1)$$

求解特征值问题:

$$\lambda \mathbf{V} = C \mathbf{V} \quad (2)$$

其中,特征值  $\lambda > 0$ , 特征向量  $\mathbf{V} \in \psi(\cdot)$ . 式 (2) 两边左乘  $\varphi(x_k)$ , 可得:

$$\lambda (\varphi(x_k) \cdot \mathbf{V}) = (\varphi(x_k) \cdot C \mathbf{V}), \quad k = 1, \dots, l \quad (3)$$

由于特征值  $\lambda \neq 0$  对应的特征向量  $\mathbf{V}$  是由特征空间的向量组成, 所以存在

$$\mathbf{V} = \sum_{i=1}^l \alpha_i \varphi(x_i) \quad (4)$$

其中  $\alpha_i$  为系数. 由式 (2)-(4) 可得:

$$\lambda \sum_{i=1}^l \alpha_i (\varphi(x_i) \cdot \varphi(x_k)) = \frac{1}{l} \sum_{i=1}^l \alpha_i (\varphi(x_k) \cdot \sum_{j=1}^l \varphi(x_j) \varphi(x_j)^T \varphi(x_i)), \quad k = 1, \dots, l \quad (5)$$

定义  $l \times l$  矩阵  $\mathbf{K}$ :

$$\mathbf{K}_{ij} = \mathbf{K}(x_i, x_j) = (\varphi(x_i) \cdot \varphi(x_j)) \quad (6)$$

则式 (5) 简化为

$$l \lambda \mathbf{K} \boldsymbol{\alpha} = \mathbf{K}^2 \boldsymbol{\alpha} \quad (7)$$

求解式 (7), 只需求解下式即可

$$l\lambda\alpha = K\alpha, \alpha = (\alpha_1, \dots, \alpha_l)^T \quad (8)$$

特征值  $\lambda_k$  和相应的特征向量  $\alpha_k (k = 1, \dots, l)$  可由上式求解, 可以得到特征值  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_l$  和特征向量  $\alpha_1, \alpha_2, \dots, \alpha_l$ . 我们可以用保留前  $p$  个特征向量的方法使系统降维. 通过特征空间向量的归一化, 我们可以使特征向量  $\alpha_1, \alpha_2, \dots, \alpha_p$  也被归一化, 即对一切  $k = 1, \dots, p$ , 令

$$(\nu_k \cdot \nu_k) = 1 \quad (9)$$

将 (4) 代入 (9) 可得:

$$\sum_{i=1}^l \sum_{j=1}^l \alpha_i^k \alpha_j^k (\varphi(x_i) \cdot \varphi(x_j)) = \sum_{i=1}^l \sum_{j=1}^l \alpha_i^k \alpha_j^k K_{ij} = (\alpha_k, K\alpha_k) = \lambda_k (\alpha_k \cdot \alpha_k) = 1 \quad (10)$$

测试向量  $x$  的主元可通过  $\varphi(x)$  映射到特征空间的特征向量得到, 即

$$t_k = (\nu_k \cdot \varphi(x)) = \sum_{i=1}^l \alpha_i^k (\varphi(x_i) \cdot \varphi(x_j)) = \sum_{i=1}^l \alpha_i^k K(x_i, x), \quad k = 1, \dots, p \quad (11)$$

如主元分析算法, 数据需要在特征空间中心化. 这个工作可以由  $\tilde{K}$  取代  $K$  来实现:

$$\tilde{K} = K - LK - KL + LKL \quad (12)$$

式中,  $L_{i,j} = 1/l$ .

与主元分析一样, 核主元分析也用 Hotelling  $T^2$  统计量和 SPE 统计量进行过程监控. 其中  $T^2$  统计量定义为:  $T^2 = [t_1, \dots, t_p] \Lambda^{-1} [t_1, \dots, t_p]^T$ , 其中  $t_k$  由式 (11) 计算得到,  $\Lambda$  是相应保留主元的特征值的对角矩阵.  $T^2$  统计量的控制限可由  $F$  分布计算得到:  $T_{p,l,a}^2 \sim \frac{p(l-1)}{l-p} F_{p,l-p,a}$ . 式中,  $l$  是核主元模型的样本数,  $p$  是保留的主元数.

基于核主元模型的 SPE 统计量控制限可由如下方法得到<sup>[9]</sup>:  $SPE = \|\hat{\varphi}_n(x) - \hat{\varphi}_p(x)\|^2 = \sum_{j=1}^n t_j^2 - \sum_{j=1}^p t_j^2$  其中  $p$  为保留的主元个数,  $n$  为式 (8) 中所有  $l$  个特征值中的非零特征值的个数; 当  $j = k$  时  $\nu_j^T \nu_k = 1$ , 否则  $\nu_j^T \nu_k = 0$ .

SPE 统计量的控制限可由下面的近似分布计算得到:  $SPE_a \sim gx_h^2$ . 式中,  $g$  反映了 SPE 统计量控制限的幅度, 而  $h$  反映了 SPE 统计量的自由度. 如果  $a$  和  $b$  分别为 SPE 的期望均值和方差, 则可近似得到  $g = b/2a, h = 2a^2/b$ .

### 3 支持向量机的多类分类算法

SVM<sup>[10-12]</sup> 是一种泛化能力很强的分类器, 它在解决小样本问题方面表现出了许多特有的优势, 已成为国际上模式识别领域新的研究热点.

对于多类模式识别问题, SVM 可通过两类问题的组合来实现. 通常有两种策略: 1) “一对多”策略, 即一个分类器将每一类与剩下所有类别区分开来; 2) “一对一”策略, 即一个分类器将两个类别对区分开来. 但两种方法将多类问题转换为两类问题求解时, 往往会出现拒绝分类区, 为了避免这种情况, Yuan 等提出“一对其余”算法<sup>[13]</sup>.

由于上述“1 对其余”算法以多数出现的故障或较危险故障来优先考虑训练 SVM, 一定程度上影响了训练、分类速度, 为此, 提出一种改进“1 对其余”算法, 即根据各类数据的中心距离, 先对训练数据进行划分, 再使用 SVM 进行分类, 大大减少了重复训练量<sup>[14]</sup>.

具体过程如下:

- 1) 根据各类数据在特征空间中的中心距离, 将样本数据按距离由远到近排序;
- 2) 从  $k$  类中选出距离最远的一类数据作为单独的一类, 剩下的  $k-1$  类看作一类, 使用 SVM 进行分类. 分类后下一步不再考虑这单独的一类, 而只考虑所合并的  $k-1$  类;
- 3) 从  $k-1$  类中选出中心距离最远的一类作为单独的一类, 再把剩下  $(k-1)-1$  类看作一类, 使用 SVM 进行分类;

4) 依此类推, 直到最后两类判决.

## 4 基于核主元分析和多支持向量机分类的密闭鼓风炉监控诊断模型

### 4.1 建立正常状态下的 KPCA 过程监控模型

1) 获得过程正常运行下的操作数据, 并对每个数据按式 (13) 用均值和标准差进行标准化处理:

$$X_i^* = \frac{X_i - E(X_i)}{(\text{Var}(X_i))^{1/2}}, \quad i = 1, \dots, l \quad (13)$$

2) 对于采集到的  $m$  维过程正常操作数据  $X_k \in \mathbf{R}^m$ , ( $k = 1, \dots, l$ ), 由式

$$[\mathbf{K}]_{ij} = \mathbf{K}_{ij} = \langle \varphi(x_i), \varphi(x_j) \rangle = [\mathbf{K}(x_i, x_j)] \text{ 计算核矩阵 } \mathbf{K} \in \mathbf{R}^{l \times l};$$

3) 依据式 (12) 对核矩阵  $\mathbf{K}$  进行中心化处理;

4) 求解特征值问题  $l\lambda\alpha = \tilde{\mathbf{K}}\alpha$ , 并对  $\alpha_k$  归一化处理, 使得  $\langle \alpha_k, \alpha_k \rangle = 1/\lambda_k$ ;

5) 依据式 (11) 对正常操作数据集, 提取非线性特征元 (即核主元);

6) 计算正常操作数据的统计量  $T^2$  或 SPE;

7) 计算统计量  $T^2$  或 SPE 相应的控制限 (对应于 99%置信限);

### 4.2 建立多支持向量机故障诊断模型

8) 获得故障数据集, 并由式 (11) 计算故障数据的核主元作为多支持向量机分类器的训练数据, 记为  $(x_1, y_1), \dots, (x_l, y_l)$ ,  $k \in \mathbf{R}^p \times \{+1, -1\}$  ( $l$  样本数,  $p$  为支持向量机输入向量的维数, 亦即故障数据的核主元数目);

9) 通过选择合适的核函数  $\mathbf{K}(x_i, \mathbf{x})$  和正规化参数  $c$ , 利用训练数据  $(x_i, y_i)$  获得支持向量机模型的解;

10) 通过上面的条件, 获得第  $q$  个支持向量分类器的模型为:  $f_q(x) = \text{sgn} \left( \sum_{i=1}^p a_i y_{qi} \mathbf{K}(x_i, \mathbf{x}) + b \right)$ ;

11) 重复第 (9) 步  $n$  次, 直到获得所有  $n$  个支持向量分类器;

### 4.3 在线监控和故障诊断

12) 获取新的样本数据并进行标准化处理;

13) 对于  $m$  维测试数据  $\mathbf{x}_t \in \mathbf{R}^m$ , 通过核方法  $[\mathbf{k}_t]_j = [\mathbf{K}(x_t, x_j)]$  计算核矢量  $\mathbf{k}_t \in \mathbf{R}^{1 \times l}$ ,  $x_j$  为正常操作数据,  $x_j \in \mathbf{R}^m$ ,  $j = 1, \dots, l$ ;

14) 依据式 (12) 对测试核矢量  $\mathbf{k}_t$  进行中心化处理;

15) 依据式 (11) 对测试数据集, 提取非线性特征元 (即核主元);

16) 计算测试数据的统计量  $T^2$  或 SPE;

17) 监控统计量  $T^2$  或 SPE 是否超过控制限, 若超过控制限, 则将故障数据的核主元送入到多支持向量机分类器进行分类判别;

18) 输出故障信号.

## 5 应用实例

整个熔炼过程中控制的还原能力比炼铅鼓风炉强, 比炼铁高炉弱. 当烧结过程生产出具有一定强度和透气性的烧结块后, 按一定比例与预热过的焦炭一起装入密闭鼓风炉内. 密闭鼓风炉从不同的风口向炉内鼓入热风, 其中炉底风口的热风温度较高, 具有一定热量的氧气与焦炭中的碳反应生成一氧化碳, 并放出大量的热, 进一步为氧化物的还原反应提供热量. 而一氧化碳 CO 用于还原氧化锌  $ZnO$  和氧化铅  $PbO$ <sup>[15]</sup>.

由于密闭鼓风炉是一个封闭的空间, 冶金化学反应在里面激烈进行. 为了保证密闭鼓风炉的正常生产, 所需检测数据也非常多, 目前熔炼过程有关的检测参数有 123 个. 熔炼过程最关键的问题是维持炉况的稳定, 并对当前炉况做出判断, 及时通过检测数据的变化, 获得工况变化的趋势. 例如炉内结瘤引起的清炉休风就使企业损失上百万元. 本文采用某冶炼厂密闭鼓风炉 (ISF) 的实际数据进行仿真分析研究, 以验证算法的有效性.

根据现场调研和专家经验, 密闭鼓风机主要状态有五个: 正常状态 ( $S_0$ )、悬料 ( $S_1$ )、炉渣粘结 ( $S_2$ )、炉身结瘤 ( $S_3$ )、炉顶结瘤 ( $S_4$ ); 在实际的生产控制过程中, 很多检测数据是为了监视密闭鼓风炉的生产状况的, 实际能直接反应炉况的数据只有一部分. 根据几十年的生产情况和专家经验, 选取主要的 20 个变量来对炉况进行 KPCA 研究, 列于表 1 中.

表 1 密闭鼓风机过程变量表

变量代码	类型	长度	变量名	变量代码	类型	长度	变量名
TI4107	N	4.0	热风温度	FIC3004	N	4.0	二次风量
PI3001	N	5.1	热风压力	FI3005A	N	4.0	二次风西北
FI4110B	N	5.2	热风流量	FI3005B	N	4.0	二次风东南
PI3002	N	5.1	冷风压力	FI3004C	N	4.0	二次风西南
FI4202	N	5.2	冷风流量	FI3004D	N	4.0	二次风东北
FI3002	N	4.0	料钟风	FI3335	N	5.2	底部风
FI3003	N	4.0	煤气流量	PI3001A	N	5.1	底部风压力
PI3005	N	4.0	煤气压力	FRC3005	N	5.1	风比
FI3004A	N	4.0	周边风南	TI3001A	N	4.0	炉顶温度东
FI3004B	N	4.0	周边风北	TI3001B	N	4.0	炉顶温度


### 5.1 密闭鼓风炉的核主元分析模型建立及其分析

以某冶炼厂密闭鼓风机为例来建立 KPCA 模型. 首先取正常工况下的 20 个过程变量的 350 个采样数据. 由于数据采样周期为 3 分钟/次, 这相当于采集正常运行 20 个小时的数据建立 KPCA 模型, 这样可以保证模型的可靠性.

经过多次取值试验, KPCA 中的核函数采用径向基函数, 取  $\sigma=0.10$ , KPCA 可以达到较好的降维和分类效果.

由于前 6 个主元的方差累计和百分比大于 85%, 故取核主元数为  $K=6$ . 相应的控制限  $\delta_T^2=8.5804$ , 对应于 99% 的置信限.

下面以故障 1 ( $S_1$ ) 状态为例进行分析. 在故障 1 状态下, 获得 150 组测试数据用于过程在线监控 (采样时间为 3 分钟). 为了进行对比, PCA 方法也被用来进行过程监控, 其主元数为 6, SPE 统计量控制限为 16.35, 对应于 99% 的置信限. 故障 1 的 SPE 统计量图如图 1 所示, 图中虚线表示控制限.

图 1  $S_1$  的 SPE 统计量过程监控图

从图中可知, 基于 KPCA 的过程监控要优于传统的 PCA 方法. 传统的 PCA 方法不仅误判率高, 甚至有无法判断故障存在的情况. 而基于 KPCA 的方法误判率低, 达 100% 的判别率.

因此, 可以利用 KPCA 模型得到各类型样本数据的统计量变化来监控密闭鼓风机熔炼生产过程. 根据变化, 可以确定是否出现故障, 若有故障, 再利用支持向量机对其进行识别分类.

### 5.2 多类 SVM 故障诊断系统的训练

每个变量在每一种状态下各获取 30 组数据, 利用支持向量机对经核主元分析得到的 150 组训练样本进行训练, 150 组训练数据中正常状态、悬料、炉渣粘结、炉身结瘤、炉顶结瘤 5 种类型的样本数分别为 30. 分类采用“1 对其余”算法, 共构建 4 个支持向量机 (SVM1-SVM4). 经过类中心距离划分, 5 类样本按距离由远到近的次序为: 正常状态、悬料、炉渣粘结、炉身结瘤、炉顶结瘤. 因此, SVM1 用 150 个样本进行训练,

SVM2 用悬料、炉渣粘结、炉身结瘤、炉顶结瘤 120 个样本进行训练, SVM3 用炉渣粘结、炉身结瘤、炉顶结瘤 90 个样本进行训练, SVM4 用炉身结瘤、炉顶结瘤 60 个样本进行训练. 经过比对分析, 选择 Gauss 型函数作为 SVM 核函数, 取  $C=1$ ,  $\delta^2 = 1$ .

### 5.3 鼓风炉故障的分类诊断

为了进一步验证 KPCA-MSVM 的有效性, 利用密闭鼓风炉 (ISF) 已知故障类别的检验样本进行验证. 每种状态选取了 20 个样本, 5 种状态共 100 个样本分别用 PCA-MSVM 和 KPCA-MSVM 方法测试和进行对比试验, 结果如表 2 所示.

表 2 故障分类诊断结果

故障类型	检验样本数	多支持向量机分类器的分类结果		KPCA-MSVM 和 PCA-MSVM 诊断结果对比	
		训练结果	测试结果	PCA-MSVM	KPCA-MSVM
$S_0$	20	100.0	100.0	90.0	100.0
$S_1$	20	96.7	95.0	90.0	95.0
$S_2$	20	93.3	85.0	75.0	85.0
$S_3$	20	96.7	90.0	85.0	90.0
$S_4$	20	96.7	95.0	85.0	95.0

从表 2 结果可以看出, 多支持向量机可以有效地分离出各个故障.

从 KPCA-MSVM 诊断结果及与 PCA-MSVM 的对比中可以看出, 相对于 PCA-MSVM 方法, KPCA-MSVM 方法具有较高的故障识别率, 其性能优于 PCA-MSVM 方法且 MSVM 相对于 SVM 在识别率基本不变的情况下, 训练速度可以提高 2—3 倍, 特别是在数据量较大时优势更加明显.

实验证明, MSVM 方法用于在线故障诊断时, 计算量并不是非常大, 对计算机的要求也并不高, 这是因为大量的计算和训练工作主要集中在离线过程和建模阶段, 在线监测仅仅是一个模式匹配的过程. 另外若故障模式发生变化, 只需重新训练对应的 MSVM 即可.

## 6 结论

本文针对密闭鼓风炉熔炼过程难于建模的实际问题, 提出了基于核主元分析和多支持向量机的过程监控模型, 模型具有如下特点:

- 1) 发挥了核主元分析与多支持向量机技术各自的优势, 具有所需建模样本少、学习能力强的特点;
- 2) 预测结果表明, 这种建模方法泛化能力好, 抗噪性强, 能快速反应整个生产过程的变化和故障的出现, 在过程工业的监控领域具有巨大的应用价值.

## 参考文献

- [1] 刘晓颖, 桂卫华, 朱爽. 铅锌冶炼过程的故障诊断神经网络专家系统 [J]. 上海海运学院学报, 2001, 22(3): 97-99.  
Liu X Y, Gui W H, Zhu S. Fault diagnosis on neural network expert system for Lead and Zinc smelting process[J]. Journal of Shanghai Maritime University, 2001, 22(3): 97-99.
- [2] 唐朝晖, 桂卫华, 吴敏. 密闭鼓风炉铅锌熔炼的统计过程监测系统设计 [J]. 计算机与应用化学, 2007, 24(2): 155-158.  
Tang Z H, Gui W H, Wu M. Statistical monitoring system design for imperial smelting furnace of Pb-Zn smelting process[J]. Computers and Applied Chemistry, 2007, 24(2): 155-158.
- [3] Akbarvan F, Bishnoi P R. Fault diagnosis of multivariate systems using pattern recognition and multi-sensor data analysis technique[J]. Computers and Chemical Engineering, 2001, 25: 1313-1339.
- [4] 徐章遂, 房立清, 王希武, 等. 故障诊断信息原理及应用 [M]. 北京: 国防工业出版社, 2000: 33-35.  
Xu Z S, Fang L Q, Wang X W, et al. Fault Diagnosis Information Principle and Its Applications[M]. Beijing: National Defence Industry Press, 2000: 33-35.
- [5] Scholkopf B, Smola A, Müller K R. Nonlinear component analysis as a kernel eigenvalue problem[J]. Neural Computation, 1998, 10(5): 1299-1319.

- [6] Scholkopf B, Smola A, Muller K R. Kernel principal component analysis[C] // *Advances in Kernel Methods-support Vector Learning*, Cambridge MA: MIT Press, 1999: 327–352.
- [7] 于德介, 陈森峰, 程军圣, 等. 基于 AR 模型和支持向量机的转子系统故障诊断方法 [J]. *系统工程理论与实践*, 2007, 27(5): 152–157.  
Yu D J, Chen M F, Cheng J S, et al. Fault diagnosis approach for rotor systems based on AR model and support vector machine[J]. *Systems Engineering — Theory & Practice*, 2007, 27(5): 152–157.
- [8] 刘爱伦, 袁小艳, 俞金寿. 基于 KPCA-SVC 的复杂过程故障诊断 [J]. *仪器仪表学报*, 2007, 28(5): 868–872.  
Liu A L, Yuan X Y, Yu J S. Fault diagnosis of complex chemical process based on KPCA-SVC[J]. *Chinese Journal of Scientific Instrument*, 2007, 28(5): 868–872.
- [9] Lee J M, Yoo C K, et al. Nonlinear process monitoring using kernel principal component analysis[J]. *Chemical Engineering Science*, 2004, 59: 223–234.
- [10] Cortes C, Vapnic V. Support vector networks[J]. *Machine Learning*, 1995, 20(1): 1–25.
- [11] Burges C J C. A tutorial on support vector machines for pattern recognition[J]. *Data Mining and Knowledge Discovery*, 1998, 2(2): 1–48.
- [12] Vapnic V. *Statistical Learning Theory*[M]. New York: Wiley, 1998.
- [13] Yuan S F, Chu F L. Support vector machines-based fault diagnosis for turbo-pump rotor[J]. *Mechanical Systems and Signal Processing*, 2006, 20(4): 939–952.
- [14] Jiang S H, Gui W H, Yang C H, et al. Fault diagnosis of Lead-Zinc smelting furnace based on multi-class support vector machines[C]//2007 IEEE International Conference on Control and Automation, Guangzhou, 2007: 1643–1648.
- [15] Shaoguan Smelting Factory. Shaoguan smelting factory train course(interior handbook)[K]. 1994.