

研究论文

# 基于核 Fisher 判别分析方法的非线性统计 过程监控与故障诊断

赵 旭, 阎威武, 邵惠鹤

(上海交通大学自动化系, 上海 200240)

**摘要:** 化工过程中大量的生产数据反映了生产过程的内在变化和系统的运行状况, 基于数据驱动的统计方法可以有效地对生产过程进行监控。对于复杂的化工和生化过程, 其过程变量之间的相关关系往往具有很强的非线性特性, 传统的线性统计过程监控方法显得无能为力。本文提出了基于核 Fisher 判别分析的非线性统计过程监控方法, 首先利用非线性核函数将数据从原始空间映射到高维空间, 在高维空间中利用线性的 Fisher 判别分析方法提取数据最优的 Fisher 特征矢量和判别矢量来实现过程监控与故障诊断, 能有效地捕获过程变量之间的非线性关系, 通过对流化催化裂化 (FCCU) 过程的仿真表明该方法的有效性。

**关键词:** 核 Fisher 判别分析; 非线性; 统计过程监控; 故障诊断

中图分类号: TP 277

文献标识码: A

文章编号: 0438-1157 (2007) 04-0951-06

## Nonlinear statistical process monitoring and fault diagnosis based on kernel Fisher discriminant analysis

ZHAO Xu, YAN Weiwu, SHAO Huihe

(Department of Automation, Shanghai Jiao Tong University, Shanghai 200240, China)

**Abstract:** The data collected from the chemical process reflect the process change and the state of the system, and the data-driven statistical method can efficiently monitor the process. However, for some complicated cases in industrial chemical and biological processes, the conventional linear statistical methods have poor ability of monitoring those processes, because the correlation between the process variables show particularly nonlinear characteristics. In this paper, a nonlinear statistical process monitoring and fault diagnosis method based on kernel Fisher discriminant analysis (KFDA) was proposed. The basic idea of KFDA is to first map the original space into a high dimension feature space *via* nonlinear mapping and then extract the optimal Fisher feature vector and discriminant vector to achieve process monitoring and fault diagnosis. The proposed method can effectively capture the nonlinear relationship in process variables. It was evaluated by the application to the fluid catalytic cracking unit (FCCU) model and its effectiveness was demonstrated.

**Key words:** kernel Fisher discriminant analysis; nonlinear; statistical process monitoring; fault diagnosis

2006-06-07 收到初稿, 2006-11-09 收到修改稿。

联系人: 邵惠鹤。第一作者: 赵旭 (1977-), 男, 博士研究生。

基金项目: 国家自然科学基金项目 (60504033); 工业控制技术国家重点实验室开放课题基金项目 (0708004)。

Received date: 2006-06-07.

Corresponding author: Prof. SHAO Huihe. E-mail: hhshao@sjtu.edu.cn

Foundation item: supported by the National Natural Science Foundation of China (60504033) and Open Fund of National Lab. of Industrial Control Technology of China (0708004).

## 引 言

化工过程产生了大量的过程数据,通过对过程数据的统计分析可以监测系统的运行状况,评估控制性能的优劣以及对出现的故障情况进行判断。这种基于数据驱动的统计过程监控方法已在化工过程中得到了广泛的应用<sup>[1-2]</sup>。

统计过程监控根据正常工况的历史数据,使用数理统计理论建立统计监控模型,用于在线的生产过程监控。该统计模型降低了过程变量中数据的维数,消除了变量之间的相关关系,提取出正常工况数据的重要信息。目前广泛使用的统计方法有主元分析(PCA)、Fisher 判别分析(FDA)、规范变量分析(CVA)和偏最小二乘(PLS)等方法。然而这些方法都是基于线性变换的统计方法<sup>[3]</sup>,即假定过程变量之间满足线性相关关系。但是对于复杂的化工过程,变量之间往往呈现出非线性的相关关系特性,利用传统的统计方法将给过程监控带来较大的误差,增大过程故障误报、漏报的概率。

本文将机器学习中的核方法<sup>[4]</sup>引入到过程监控中,提出了基于核 Fisher 判别分析的非线性统计过程监控方法。该方法通过非线性映射将过程数据从原始空间映射到高维的特征空间,非线性映射是通过定义适当的内积核函数实现的。在高维的特征空间中进行 Fisher 判别分析,求出满足最大分离程度的判别矢量和对应的特征矢量。过程监控通过比较最优特征矢量之间的欧氏距离来实现,而最优的判别矢量用来鉴别故障类型。通过对流化催化裂化过程的数值研究,验证了方法的有效性。

## 1 核 Fisher 判别分析

Fisher 判别分析是模式识别领域广泛应用的一种分类方法,它根据最大化类间离散度、同时最小化类内离散度的准则,确定一系列线性变化方向,使各类之间最大程度的分离。当变量之间呈现非线性特性的时候,很难找到线性的变化方向使类间的数据最大程度的分离。Mika 等<sup>[5]</sup>最早提出了核 Fisher 判别分析方法,它是一种非线性的分类方法。该方法在高维特征空间中得到的线性最优判别特征实质为原始空间中非线性最优判别特征。

设采样数据矩阵  $\mathbf{X}$  由  $N$  个观测矢量  $\mathbf{x} \in R^n$  构成,共包含  $M$  个模式类,每一类中包含  $N_i$  ( $i=1,$

$2, \dots, M$ ) 个矢量。经过非线性映射  $\Phi$  后对应的模式矢量为  $\Phi(\mathbf{x}) \in H$ , 在高维特征空间  $H$  中训练样本的类内散度矩阵  $\mathbf{S}_w^\Phi$ 、类间散度矩阵  $\mathbf{S}_b^\Phi$  分别为

$$\mathbf{S}_w^\Phi = \frac{1}{N} \sum_{i=1}^M \sum_{j=1}^{N_i} [\Phi(\mathbf{x}_j^i) - m_i^\Phi][\Phi(\mathbf{x}_j^i) - m_i^\Phi]^\top \quad (1)$$

$$\mathbf{S}_b^\Phi = \sum_{i=1}^M \frac{N_i}{N} (m_i^\Phi - m_o^\Phi)(m_i^\Phi - m_o^\Phi)^\top \quad (2)$$

其中,  $\Phi(\mathbf{x}_j^i)$  ( $i=1, \dots, M; j=1, \dots, N_i$ ) 表示特征空间  $H$  中第  $i$  类第  $j$  个采样矢量。 $m_i^\Phi$  为特征空间  $H$  中第  $i$  类采样均值,  $m_o^\Phi$  为特征空间  $H$  中全体采样均值。 $\mathbf{S}_w^\Phi$  和  $\mathbf{S}_b^\Phi$  均为非负定对称矩阵。在特征空间  $H$  中 Fisher 判别准则定义为

$$J(\mathbf{w}) = \frac{\mathbf{w}^\top \mathbf{S}_b^\Phi \mathbf{w}}{\mathbf{w}^\top \mathbf{S}_w^\Phi \mathbf{w}} \quad (3)$$

其中,  $\mathbf{w}$  为任一非零列矢量, Fisher 判别分析就是通过最优化准则函数(3)找到最佳的判别矢量  $\mathbf{w}_{opt}$ , 过程数据在判别矢量上的投影作为其特征矢量。

由于特征空间  $H$  的维数很高,不可能直接计算出最佳的判别矢量。由机器学习中的再生核理论<sup>[2]</sup>可知,以上运算可以通过原始空间中定义的内积核函数来进行,并不涉及到具体的非线性映射。所以需要对准则函数进行变换,使它包含映射后数据的内积运算。内积运算用恰当的核函数来表示

$$K(\mathbf{x}_i, \mathbf{x}_j) = \langle \Phi(\mathbf{x}_i), \Phi(\mathbf{x}_j) \rangle \quad (4)$$

Mercer 给出了一个函数成为核函数的充分必要条件,即核函数是满足 Mercer 定理的任意对称函数。常用的核有多项式核、指数核、高斯核等<sup>[6]</sup>,任何一个最优化准则函数(3)的解矢量  $\mathbf{w}$  一定位于由高维空间  $H$  中的所有数据样本  $\Phi(\mathbf{x}_1), \dots, \Phi(\mathbf{x}_N)$  张成的空间内

$$\mathbf{w} = \sum_{i=1}^N a_i \Phi(\mathbf{x}_i) = \Phi \alpha \quad (5)$$

其中,  $\Phi = [\Phi(\mathbf{x}_1), \dots, \Phi(\mathbf{x}_N)]$ ;  $\alpha = (a_1, \dots, a_N)^\top \in R^N$ 。

把特征空间  $H$  中的采样值  $\Phi(\mathbf{x}_i)$  投影到  $\mathbf{w}$  上

$$\mathbf{w}^\top \Phi(\mathbf{x}_i) = \alpha^\top \Phi^\top \Phi(\mathbf{x}_i) = \alpha^\top [\Phi(\mathbf{x}_1)^\top \Phi(\mathbf{x}_i), \dots, \Phi(\mathbf{x}_N)^\top \Phi(\mathbf{x}_i)]^\top = \alpha^\top \xi_i \quad (6)$$

对于原始空间的采样矢量  $\mathbf{x} \in R^n$ , 令  $\xi_x = [K(\mathbf{x}_1, \mathbf{x}), \dots, K(\mathbf{x}_N, \mathbf{x})]^\top$ , 则称  $\xi_x$  为核采样矢量。同理把特征空间  $H$  中的类内采样均值

$m_i^\phi$  ( $i=1, \dots, M$ ) 和总体采样均值  $m_o^\phi$  投影到  $w$  上, 可以得出类内的核采样均值  $\mu_i$  ( $i=1, \dots, M$ ) 和总体核采样均值  $\mu_o$

$$\mu_i = \left[ \frac{1}{N_i} \sum_{j=1}^{N_i} \mathbf{K}(x_1, x_j^i), \dots, \frac{1}{N_i} \sum_{j=1}^{N_i} \mathbf{K}(x_N, x_j^i) \right]^T \quad (7)$$

$$\mu_o = \left[ \frac{1}{N} \sum_{i=1}^M \mathbf{K}(x_1, x_i), \dots, \frac{1}{N} \sum_{i=1}^M \mathbf{K}(x_N, x_i) \right]^T \quad (8)$$

在高维特征空间  $H$  中 Fisher 判别准则函数等价于

$$\mathbf{J}(\alpha) = \frac{\alpha^T \mathbf{K}_b \alpha}{\alpha^T \mathbf{K}_w \alpha} \quad (9)$$

其中,

$$\mathbf{K}_w = \frac{1}{N} \sum_{i=1}^M \sum_{j=1}^{N_i} (\xi_{x_j^i} - \mu_i)(\xi_{x_j^i} - \mu_i)^T \quad (10)$$

$$\mathbf{K}_b = \sum_{i=1}^M \frac{N_i}{N} (\mu_i - \mu_o)(\mu_i - \mu_o)^T \quad (11)$$

$\mathbf{K}_w$  和  $\mathbf{K}_b$  分别称为核类内散度矩阵和核类间散度矩阵。

把式 (9) 判别准则函数称为核 Fisher 判别准则函数, 其中  $\alpha$  为任一  $N$  维的非零矢量。使核 Fisher 判别准则函数取最大值所对应的判别矢量为最优的核判别矢量  $\alpha_{\text{opt}}$ , 它可以通过求解广义特征方程得到

$$\mathbf{K}_b \alpha = \lambda \mathbf{K}_w \alpha \quad (12)$$

式中  $\alpha_{\text{opt}}$  为广义特征方程的最大的特征值所对应的特征向量。

## 2 基于核 Fisher 判别分析方法的非线性统计过程监控与故障诊断

引入核将数据从原始空间映射到高维空间, 把原始空间中数据之间的非线性关系转变成高维特征空间中的线性关系, 再利用 Fisher 判别分析提取最优的判别矢量和特征矢量。基于主元分析的监控方法是利用了 Hotelling  $T^2$  和  $Q$  统计量分别对 PCA 模型的主元变量和残差变量进行监控。其中  $T^2$  统计量是用来度量主元得分的变化大小, 其本质是一种加权的统计距离<sup>[7]</sup>。而核 Fisher 判别分析方法也是利用距离作为统计量, 通过比较当前数据集和参考数据集之间最优的核 Fisher 特征矢量的欧氏距离进行过程监控。

传统的统计过程故障诊断是利用贡献图的方法实现的, 当故障发生时, 计算各变量对故障的贡献率来大致判断故障的原因。而核方法将数据映射到高维的特征空间中, 很难找到一个逆映射来计算原始空间中变量对故障的贡献率。基于核 Fisher 故

障诊断是根据提取出的历史故障数据集中最优的核 Fisher 判别矢量, 通过模式匹配来实现故障诊断的。在 Fisher 判别分析中, 从每一类故障数据中提取最优的 Fisher 判别矢量都是不同的, 计算与当前最优判别矢量相似程度最大的判别矢量所对应的故障被认为是当前过程的故障。在实际应用中, 设定一个诊断阈值  $\tau$ , 若当前的判别矢量与任一故障数据集的判别矢量的相似度都小于该诊断阈值, 则很可能是一个新的未被辨识的故障出现了, 可以结合工艺知识确定故障的类型。并将新的最优判别矢量添加到故障数据集的判别矢量中。

统计过程监控需要设定统计量的控制限来判断是否有异常情况发生。而控制限的构建需要了解统计量的分布。主元分析监控方法中确定  $T^2$  统计量的控制限时, 假定提取出的主元变量服从同一高斯分布, 则  $T^2$  统计量近似服从  $F$  分布<sup>[8]</sup>。对于本文定义的核 Fisher 空间中的距离统计量, 无法知道其确切的统计分布, 只能通过大量的数据来提供其分布信息。本文采用一种基于数据驱动的非参数统计方法, 核密度估计方法<sup>[9]</sup>, 来计算统计量的概率密度函数, 进而确定统计控制限。

单变量核密度估计的定义为

$$\hat{f}(x) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{x-x_i}{h}\right) \quad (13)$$

其中,  $x_i$  为数据集的观测值,  $n$  表示观测值的数量,  $h$  为平滑参数,  $K(x)$  表示核函数。在平滑参数  $h$  的选取中, 最简单的方法是先假定数据的分布再根据分布知识来估计平滑参数。但如果假定的数据分布有误差的话, 常会带来欠平滑或过平滑的问题。本文选取了最小二乘交叉检验的方法<sup>[10]</sup>来确定  $h$  的大小。首先求取正常工况下数据最优的核 Fisher 特征向量之间的欧氏距离  $D_{\text{nor}}$ 。再利用式 (13) 计算统计量  $D_{\text{nor}}$  的概率密度函数。求出概率密度为 99% 时所对应的点  $x$  作为置信度为 99% 统计量的控制限  $D^*$ <sup>[11]</sup>。

核 Fisher 判别分析过程监控和故障诊断的步骤如下。

(1) 选择适当的核函数, 将参考数据  $X_{\text{ref}}$  和新采样的数据  $X_{\text{new}}$  通过非线性的核函数从原始空间映射到高维特征空间, 得到核参考数据集  $\xi_{X_{\text{ref}}}$  和新的核采样数据集  $\xi_{X_{\text{new}}}$ 。

(2) 将核的参考数据和新的核采样数据看作不同的模式类, 由式 (10)、式 (11) 求取核的类内

散度矩阵  $\mathbf{K}_w$  和核类间散度矩阵  $\mathbf{K}_b$ 。

(3) 求解广义的特征方程式 (12), 得到最优的核判别矢量  $\alpha_{opt}$ 。

(4) 分别将核参考数据集  $\xi_{X_{ref}}$  和新的核采样数据集  $\xi_{X_{new}}$  向最优的核判别矢量  $\alpha_{opt}$  方向投影, 得到两类数据集最优的核 Fisher 特征矢量  $\mathbf{T}_{ref}$  和  $\mathbf{T}_{new}$ 。

(5) 计算最优的核 Fisher 特征矢量之间的欧氏距离  $D = \|\mathbf{T}_{ref} - \mathbf{T}_{new}\|$ 。

(6) 当计算出的统计量  $D$  大于控制限  $D^*$  时, 则认为有故障产生。利用以下相似度系数  $S$  来判别故障的类型。

$$S = \frac{(\alpha_{opt})(\alpha_i)^T}{\|\alpha_{opt}\| \cdot \|\alpha_i\|} \quad (14)$$

其中,  $\alpha_{opt}$  是当前数据提取出的最优核 Fisher 核判别矢量,  $\alpha_i$  为历史故障数据集中提取出的最优核 Fisher 判别矢量。设故障集中共有  $n$  种故障类型 ( $i=1, \dots, n$ )。由式 (14) 可以得出, 相似度系数  $S$  其实是两个最优的核 Fisher 判别矢量间角度的余弦。当两个矢量的方向接近时, 相似度系数接近 1。

### 3 仿真研究

流化催化裂化装置 (fluid catalytic cracking unit, FCCU), 是炼油工业中最为重要的装置, 它的成功与否及效率的高低决定了炼油厂的经济效益。其工作原理是将从其他炼油装置中获得的重油原料, 在添加一定催化剂的情况下, 裂化成更轻、更有价值的产品, 如汽油或喷气燃料等。FCCU 过程中复杂的反应动力学机理以及变量

之间的强耦合和非线性关系给过程监控带来了很大的难度<sup>[12]</sup>。

本文选用的研究对象为 McFarlane 等<sup>[13]</sup> 提出的 FCCU 动态仿真模型, 其工艺流程如图 1 所示。具体的数学模型和详尽的参数设置参见文献 [13]。新鲜的原料与回炼油经预热, 进入提升管反应器与再生的催化剂相接触, 开始裂化反应。生成的油气产品进入主分馏装置, 而催化剂经蒸汽汽提置换出其中的油气后, 进入再生器, 与空气充分接触来消耗催化剂上附着的焦炭, 恢复催化剂的活性。释放的能量可以供给裂化反应所需, 多余的热量由外部的热交换器带走<sup>[14]</sup>。

历史数据集通过运行 FCCU 仿真模型得到, 其中故障数据是在正常工况条件下, 参数稳定后引入扰动或故障, 同时开始记录数据。在模拟过程中, 各观测变量和控制器的输出加入了高斯白噪声来模拟实际工况条件下的随机噪声。仿真过程共选取了 18 个过程变量, 分别是新进料流量、油浆回炼流量、进入提升管的新进料温度、加热炉燃烧室温度、燃烧供气风机的产量、燃烧供气风机进口处空气的流速、提升空气风机的转速、提升空气风机的产量、提升空气风机的吸入流速、提升管温度、湿气压缩机的吸入压强、湿气压缩机进口的流速、再生床的温度、排出烟气阀的位置、再生器的压强、竖立管催化剂的位置、烟气中氧气的浓度和燃烧供气风机释放的压强。各变量的采样间隔为 3 min, 共运行 30 h。每一组历史数据为 (600×18) 的数据矩阵。表 1 列出了模拟过程中 8 种不同的故障情况。

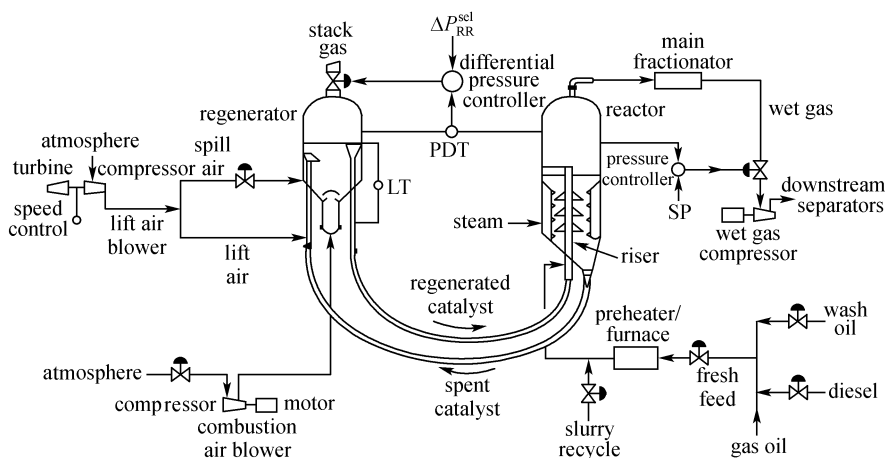


图 1 流化催化裂化装置原理图

Fig. 1 Schematic diagram of fluid catalytic cracking unit

表 1 FCCU 模型的故障工况

Table 1 Process disturbances for FCCU

Case No.	Disturbance
1	10% loss of combustion air blower capacity
2	5% degradation in the flow of regenerated catalyst
3	10% decrease in the heat exchanger coefficient of the furnace
4	5% increase in the coke factor of the feed
5	10% increase in fresh feed
6	5% decrease in lift air blower speed
7	5% increase in friction coefficient of regenerated catalyst
8	negative bias of reactor pressure sensor

从历史数据集中取 1 组正常工况的数据和 3 组不同的故障数据。用 Fisher 判别分析方法提取数据最优和次优的判别矢量，然后将数据投影到判别矢量方向上，得到数据在原始空间中 Fisher 第一和第二特征矢量的分散图，如图 2 所示。从图 2 可以看出只有故障 1 的数据被有效的区分开，正常数据，故障 2 和故障 3 的数据并不能被有效的区分开。图 3 是利用核 Fisher 判别方法得到核 Fisher 第一和第二特征矢量的分散图。由图 3 可以看出，选用恰当的核函数将数据映射到高维的特征空间后，Fisher 判别方法很容易将不同类型的数据区分开。其中核函数选用高斯核函数

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{c}\right) \quad (15)$$

参数  $c$  的选择由经验估计得出，当  $c=0.8$  时，数据类之间有较程度的分离。从以上仿真试验可以得出，核 Fisher 判别分析方法可以有效的提取非线性数据的特征矢量，将不同类型的数据有效的分离。这样使得利用最优的核 Fisher 特征矢量的欧氏距离作为统计量进行过程监控成为可能。

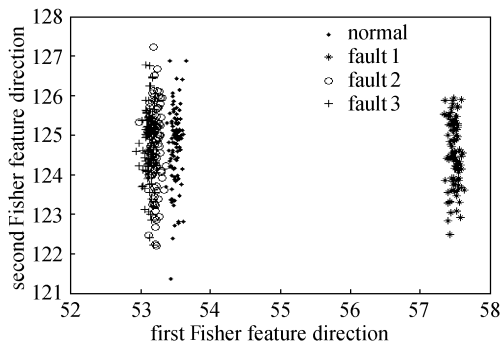


图 2 原始空间中 Fisher 特征向量分散图

Fig. 2 Scores plot in original feature space

在线过程监控时，求取正常数据集之间最优的核 Fisher 特征矢量的欧氏距离，利用核密度估计

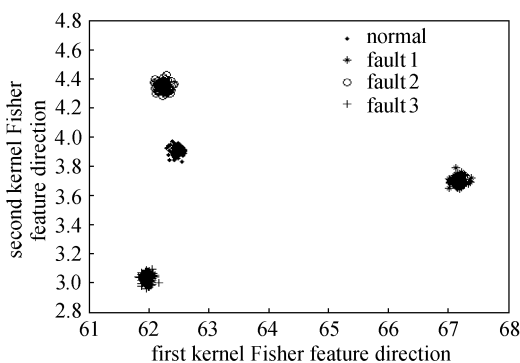


图 3 高维空间中核 Fisher 特征向量分散图

Fig. 3 Scores plot in high dimension feature space

的方法确定其置信度为 99% 的控制限。为了提高过程监控的实施性，本文采用文献 [15] 所使用的移动窗口 (moving window) 技术，通过不断更新窗口数据来达到实时监控的目的。过程的采样间隔仍为 3 min，运行时间为 36 h，窗口大小选为 20，即以 20 个数据为一个模块进行监控。故障在第 20 h 引入。图 4 为故障 3 的实时监控图，故障 3 是在第 20 h 把加热炉的传导系数降低了 10%，加热炉传导系数的降低通常是由加热炉的污垢所致。传导系数的降低会使进入提升管的进料温度低于其设定值，使裂化反应不充分。从图 4 可以看出，在第 20 h，距离统计量显著增加，超出了 99% 置信度的控制限，可以认为有故障发生。而图 5 是传统 PCA 方法的过程监控图，其中选取的主元数目为 8，对应解释的方差百分比为 85%。从图 5 可以看出  $T^2$  和 SPE 统计量只在部分时刻超出 99% 置信度的控制限，所以传统的 PCA 方法并不能有效的监测出过程的变化。故障诊断是通过比较当前数据和故障数据集中最优的核 Fisher 判别矢量的相似度来实现的。从图 6 可以看出，当前数据最优的核 Fisher 判别矢量与故障 3 的相似度最大，相似值  $S$  为 0.9238，可以判断故障来自于加热炉传导系数的降低。

## 4 结论

本文针对复杂化工过程呈现出的非线性特性，提出了一种基于核 Fisher 判别分析的非线性统计过程监控与故障诊断方法。该方法首先利用恰当的核函数将数据映射到高维空间中，使得原始空间中数据的非线性关系在高维空间中线性化，然后利用 Fisher 判别分析方法提取数据最优的特征矢量和判别矢量进行过程监控与故障诊断。通过对流化催化裂化过程的仿真研究，验证了方法的有效性和合理




图 4 故障 3 情况下核 FDA 方法在线监控图

Fig. 4 Monitoring result for case 3





图 5 故障 3 情况下 PCA 方法在线监控图

Fig. 5 PCA on-line monitoring charts for case 3




图 6 故障 3 情况下 Fisher 判别向量与历史数据库中的匹配情况

Fig. 6 Similar degree of case 3 with case in historical database

性。仿真过程中，核函数及其参数的选择对监控的性能影响较大。所以基于核的统计过程监控方法中，核函数的选择及其参数的优化方法需要进一步的研究。

## References

- [1] Kano M, Nagao S, Hasebe S. Comparison of multivariate statistical process monitoring methods with applications to the Eastman challenge problem. *Computers and Chemical Engineering*, 2002, **26**: 161-174
- [2] Lennox B, Hiden H G, Montague G. Application of multivariate statistical process control to batch operations. *Computers and Chemical Engineering*, 2001, **24**: 291-296
- [3] Chiang L H, Russell E L, Braatz R D. *Fault Detection and Diagnosis in Industrial Systems*. London: Springer Verlag, 2001
- [4] Schölkopf B, Mika S, Burges C J C, Knirsch P, Müller K, Rätsch G, Smola A J. Input space versus feature space in kernel-based methods. *IEEE Transactions on Neural Networks*, 1999, **10** (5): 1000-1016
- [5] Mika S, Rätsch G, Weston J, Schölkopf, Müller K R. Fisher discriminant analysis with kernels//*Neural Networks for Signal Processing IX*. Piscataway: IEEE Press, 1999: 41-48
- [6] Christianini N, Shawe-Taylor J. *An Introduction to Support Vector Machines and Other Kernel-Based Learning Methods*. UK: Cambridge University Press, 2000
- [7] Johnson R A, Wichern D W. *Applied Multivariate Statistical Analysis*. 3rd ed. Englewood Cliffs, New Jersey: Prentice-Hall, 1992
- [8] Tracy N D, Young J C, Mason R L. Multivariate control charts for individual observations. *Journal of Quality Technology*, 1992, **24**: 88-95
- [9] Martin E B, Morris A J. Non-parametric confidence bounds for process performance monitoring charts. *Journal of Process Control*, 1996, **6** (6): 349-358
- [10] Simoglou A, Martin E B, Morris A J. Statistical performance monitoring of dynamic multivariate processes using state space modeling. *Computers and Chemical Engineering*, 2002, **26**: 909-920
- [11] Lee J M, Yoo C K, Lee I B. Statistical process monitoring with independent component analysis. *Journal of Process Control*, 2004, **14**: 467-485
- [12] Wang X, Kruger Uwe, George W I. Process monitoring approach using fast moving window PCA. *Industry Engineer Chemical Research*, 2005 (44): 5691-5702
- [13] McFarlane R C, Reineman R C, Bartee J F, Georgakis C. Dynamic simulator for a model (IV): Fluid catalytic cracking unit. *Computers and Chemical Engineering*, 1993, **17** (3): 275-300
- [14] Guo Ming (郭明), Wang Shuqing (王树青). System performance monitoring and region identification based on characteristic subspace. *Journal of Chemical Industry and Engineering (China)* (化工学报), 2004, **55** (1): 151-154
- [15] Kano M, Hasebe S, Hashimoto I. A new multivariate statistical process monitoring method using principal component analysis. *Computers and Chemical Engineering*, 2001, **25**: 1103-1113