

Journal of System Simulation

Volume 29 | Issue 7

Article 15

6-1-2020

Application of Weighted Dynamic SVDD in Nonlinear Process Monitoring

Yanhong Xie

1. Department of Science Shenyang University of Chemical Technology, Shenyang 110142, China;;

Chengao Sun

2. College of Information Engineering Shenyang University of Chemical Technology, Shenyang 110142, China;

Li Yuan

2. College of Information Engineering Shenyang University of Chemical Technology, Shenyang 110142, China;

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>

 Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Application of Weighted Dynamic SVDD in Nonlinear Process Monitoring

Abstract

Abstract: Due to the complexity of the chemical process, the data are often characterized by dynamics and correlation between sequences. Traditional support vector data description (SVDD) methods are difficult to guarantee real-time monitoring online. A *Weighted-Dynamic-SVDD (WDSVDD) method was proposed to monitor fault in real time online. The dynamic method was introduced, and the correlation between the data was considered. The weighted information was used to highlight the useful information. The model was established by using SVDD method, and the online real-time fault monitoring was realized.* The method not only overcomes the adverse effect of non-Gaussian and nonlinearity, but also considers dynamic characteristics and correlation between sequences of the processing data. Applications in the numerical simulation and TE process instance verify the effectiveness of the proposed method.

Keywords

faulty monitoring, dynamic, SVDD (support vector data description), chemical process

Recommended Citation

Xie Yanhong, Sun Chengao, Li Yuan. Application of Weighted Dynamic SVDD in Nonlinear Process Monitoring[J]. Journal of System Simulation, 2017, 29(7): 1506-1513.

加权动态 SVDD 在非线性过程监测中的应用研究

谢彦红¹, 孙呈敖², 李元²

(1. 沈阳化工大学数理系, 辽宁 沈阳 110142; 2. 沈阳化工大学信息工程学院, 辽宁 沈阳 110142)

摘要: 由于化工过程的复杂性, 数据往往存在动态以及序列之间具有相关性特点, 传统的支持向量数据描述(Support Vector Data Description, SVDD)方法, 很难保证故障监测的准确性和实时性, 提出一种基于加权的动态 SVDD(WDSVDD)在线实时故障监测方法, 引入动态方法, 考虑了数据之间的序列相关性, 利用加权的方法把有用的信息突出显示, 利用 SVDD 方法建立模型, 实现了在线实时故障监测。该方法不仅克服了过程数据非高斯、非线性特性对故障监测带来的影响, 并且考虑了数据的动态特性和序列之间的关系, 通过在数值仿真和 TE 过程实例中的应用验证了方法的有效性。

关键词: 故障监测; 动态; 支持向量数据描述; 化工过程

中图分类号: TP277 文献标识码: A 文章编号: 1004-731X (2017) 07-1506-08

DOI: 10.16182/j.issn1004731x.joss.201707015

Application of Weighted Dynamic SVDD in Nonlinear Process Monitoring

Xie Yanhong¹, Sun Chengao², Li Yuan²

(1. Department of Science Shenyang University of Chemical Technology, Shenyang 110142, China;
2. College of Information Engineering Shenyang University of Chemical Technology, Shenyang 110142, China)

Abstract: Due to the complexity of the chemical process, the data are often characterized by dynamics and correlation between sequences. Traditional support vector data description (SVDD) methods are difficult to guarantee real-time monitoring online. A Weighted-Dynamic-SVDD (WDSVDD) method was proposed to monitor fault in real time online. The dynamic method was introduced, and the correlation between the data was considered. The weighted information was used to highlight the useful information. The model was established by using SVDD method, and the online real-time fault monitoring was realized. The method not only overcomes the adverse effect of non-Gaussian and nonlinearity, but also considers dynamic characteristics and correlation between sequences of the processing data. Applications in the numerical simulation and TE process instance verify the effectiveness of the proposed method.

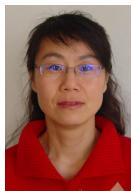
Keywords: faulty monitoring; dynamic; SVDD (support vector data description); chemical process

引言

在现代工业生产过程中, 为了保证生产过程安全运行和生产高质量的产品, 因此, 密切监视过程

装置和相关仪表的可靠性变得越来越重要。

近年来, 多元统计控制的方法已广泛应用于化学工业过程监测中, 如主元分析方法(PCA)、偏最小二乘法(PLS)等^[1-3]。这些建模方法通常假设某一时刻的观测数据和过去时刻的观测数据序列无关。但是, 在化学过程中, 当采样时间间隔较长时, 这种假设是有效的。在实际的采样过程中, 为了更好的监视生产过程, 要求比较短的采样时间间隔, 因此序列相关性是实际数据普遍具有的特点, 探讨



收稿日期: 2015-09-07 修回日期: 2016-01-09;
基金项目: 国家自然科学基金(61490701, 61174119),
辽宁省教育厅重点实验室基础研究(LZ2015059), 辽
宁省自然科学基金(2015020164);
作者简介: 谢彦红(1964-), 女, 辽宁岫岩, 硕士, 教
授, 研究方向为过程控制及故障诊断。

适合于序列相关数据的过程监测方法是非常必要的^[3-5]。针对在线过程监测中由于数据动态和没有考虑数据相关性的限制而导致监测效果的准确性和实时性不佳的问题，相继提出了动态主元分析(DPCA)、最小窗口主元分析法、基于子时段的主元分析建模等方法^[6-10]。虽然这些方法在处理存在序列相关性的数据表现出一定的优势，但都没能解决数据服从高斯分布的限制，而一些能够处理非高斯、非线性数据的方法，如多向独立元分析方法(MICA)、核独立主元分析方法(KICA)虽然能获取非高斯的数据信息，但仍存在由于初值选取的随机性导致检测结果的不稳定性、如何选取独立元、计算量大等问题^[9-11]。因此这些方法在化学工业过程故障监测中的效果并不理想。

20世纪90年代末Tax等人提出了支持向量数据描述(SVDD)方法，该方法通过非线性变换将正常数据样本空间映射到高维特征空间中建立模型，并且没有数据服从高斯分布的限制，能够运用到变量间是非线性关系的数据中，该方法虽然在处理非高斯、非线性数据中表现出极大的优势，但是由于忽略了数据之间的序列相关性，因此同样存在监测过程中实时性和准确性不高的问题^[11-16]。文献[17]中提出基于滑动窗口SVDD的故障监测方法，通过采用适当大小的滑动窗口逐步更新当前子数据空间，建立SVDD子模型，从而实现在线实时故障监测对提高在线监测过程中的实时性和准确性，改善了由于数据中的动态特性导致监测效果不佳的问题，但是该方法需要不断的更新子数据模型，过多的模型数量导致该算法的运行效率大大降低。

针对上述问题，本文综合考虑了采样数据间的序列相关性、动态性以及数据存在非高斯、非线性的限制和在线监测过程中准确性、实时性不佳的问题，提出了一种加权的动态SVDD(WDSVDD)监测方法。该方法不仅避免了传统的主元分析方法由于忽略了某一时刻的观测数据和过去时刻的观测数据序列之间的关系而造成监测效果不佳的问题，并且能够克服数据服从高斯分布和不同变量之间是

线性关系的限制，并通过加权对有用的信息加以突出，同时只需要建立一个故障监测模型，大大提高了算法的效率和故障监测能力，最后在数值仿真和TE过程中加以应用，取得了良好的监测效果。

1 SVDD 基本理论

SVDD的基本思想是针对数据集 $\mathbf{X}=\{x_i, i=1,2,\cdots,N\}$ ，通过非线性变换 $\Phi: \mathbf{X} \rightarrow \mathbf{F}$ 将原始空间数据投影到特征空间 $\{\Phi(x_i), i=1,\cdots,N\}$ ，从而找到一个几乎包含所有数据样本的最小体积超球体。假定 a 是超球体的球心， R 为超球体半径，考虑测量误差或者噪音等干扰引起的离群点影响，引入松弛因子 ξ ， C 是惩罚参数，该问题可描述为：

$$\begin{aligned} & \min R^2 + C \sum \xi_i \\ \text{s.t. } & \|\Phi(x_i) - a\|^2 \leq R^2 + \xi_i, \quad \xi_i \geq 0 \end{aligned} \quad (1)$$

上述优化问题可转化为解决相应的对偶问题：

$$\begin{aligned} L = & \sum a_i \langle \Phi(x_i) \cdot \Phi(x_i) \rangle - \\ & \sum a_i a_j \langle \Phi(x_i) \cdot \Phi(x_j) \rangle \end{aligned} \quad (2)$$

$$\text{s.t. } \sum_i a_i = 1 \quad 0 \leq a_i \leq C$$

式中： a_i 是拉格朗日因子。

用核函数 $K(x_i \cdot x_j)$ 代替内积 $\langle \Phi(x_i) \cdot \Phi(x_j) \rangle$ 以实现低维空间的非线性问题向高维空间的线性问题的转换，可得到：

$$\max L = \sum_i a_i K(x_i \cdot x_i) - \sum_{i,j} a_i a_j K(x_i \cdot x_j) \quad (3)$$

利用二次规划，可以求出 a_i ，如果 $0 < a_i < C$ ，则说明目标数据在超球面上，此时该点为支持向量；如果 $a_i=0$ ，则说明目标数据在超球体内；如果 z 是支持向量，则超球体的半径和球心为

$$\begin{aligned} R &= \sqrt{1 - 2 \sum_i a_i K(z \cdot x_i) + \sum_{i,j} a_i a_j K(x_i \cdot x_j)} \\ a &= \sum_i a_i \Phi(x_i) \end{aligned} \quad (4)$$

对于新来的样本 x_{new} ，其到超球体球心的距离可表示为

$$D_{\text{new}} = \sqrt{1 - 2 \sum_i a_i K(x_{\text{new}} \cdot x_i) + \sum_{i,j} a_i a_j K(x_i \cdot x_j)} \quad (5)$$

如果 $D_{\text{new}} < R$, 说明该样本在超球体内, 则该样本正常; 反之, 该样本在超球体外, 为异常样本。

2 加权的动态 SVDD

由于过程数据不仅包含很强的互相关性还含有自相关性, 用传统的故障监测方法虽然也有可能检测和分离出干扰, 但由于违背时间独立性假设, 以及过程数据往往存在非高斯非线性的特征, 造成对小的故障会有误报和漏报, 为了克服这些缺点, 本文在传统 SVDD 监测方法的基础上, 首先对数据进行增广, 考虑了数据的动态特性, 其次对包含信息量多的数据进行加权, 提出了加权的动态 SVDD 故障监测方法, 其中包括建立模型和监测过程两个部分。

2.1 建立模型

(1) 数据增广处理

在动态系统中, 当前时刻的数据部分取决于过去时刻的数值, 因此需要掌握当前时刻和之前时刻

间的关系。假设原始矩阵为 $\mathbf{X} = \begin{bmatrix} \mathbf{x}_1^T \\ \mathbf{x}_2^T \\ \vdots \\ \mathbf{x}_n^T \end{bmatrix}$, 增加前 l 时刻的观测数据, 得到增广的数据矩阵为:

$$\mathbf{X}(l) = \begin{bmatrix} \mathbf{x}_t^T & \mathbf{x}_{t-1}^T & \dots & \mathbf{x}_{t-l}^T \\ \mathbf{x}_{t+1}^T & \mathbf{x}_{t-2}^T & \dots & \mathbf{x}_{t-l+1}^T \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{x}_{t+n+1}^T & \mathbf{x}_{t+n-2}^T & \dots & \mathbf{x}_{t+n-l}^T \end{bmatrix}.$$

数据在 t 时刻的所有变量的集合; n 为总的采样时刻。延迟时间 l 的选择应综合考虑数据维数和序列相关性的权衡, 如果延迟时间 l 选择的过大会导致矩阵的维数过大, 导致监测效率降低, 从而影响故障监测的实时性, 反之, 如果过小, 又不能充分体现数据之间的序列相关性, 一般情况下, l 选择为 2~5。为了综合考虑矩阵的复杂度和 SVDD 的运行时间, 将增广矩阵作如下的处理, 可以得到:

$$\tilde{\mathbf{X}}(l) = \begin{bmatrix} \tilde{\mathbf{x}}_t^T \\ \tilde{\mathbf{x}}_{t-1}^T \\ \vdots \\ \tilde{\mathbf{x}}_{t+l-n}^T \end{bmatrix}$$

式中: $\tilde{\mathbf{x}}_t^T = (\mathbf{x}_t^T + \mathbf{x}_{t-1}^T + \dots + \mathbf{x}_{t-l}^T) / l$ 。

通过这步处理后, 既考虑了数据间的数据相关性, 同时没有因为数据维数的增加而降低 SVDD 本身的运行效率。

(2) 数据加权处理

给出一个权矩阵 \mathbf{W} , 则加权后的矩阵 \mathbf{X}_W 变为:

$$\mathbf{X}_W = \tilde{\mathbf{X}}(l) \times \mathbf{W} \quad (6)$$

式中: 权矩阵 $\mathbf{W} = \text{diag}(W_1, W_2, \dots, W_j)$ 是一个对角矩阵, 其中 j 为变量的个数。如果某变量包含比较多的信息, 就给这个变量赋予一个较大的权值, 反之就赋予一个较小的权值。一般认为, 如果某个变量的离散程度即方差比较大, 说明这个变量代表的信息量也比较大。本文采用变量的标准差来设置权值的大小。具体加权公式如式(7)所示。

$$w_r = \text{std}(\tilde{\mathbf{X}}(r)) \quad r = (1, 2, \dots, j) \quad (7)$$

式中: $\text{std}(\tilde{\mathbf{X}}(r))$ 是训练数据第 r 个变量的标准差。经过加权, 重要的信息得到突出显示, 但由于数据之间不服从高斯分布且变量之间的关系是非线性, 考虑到这种情况, (因为 SVDD 方法不需要数据服从高斯分布以及变量之间关系是线性的假设), 因此利用 SVDD 方法建模, 利用公式(4)求出超球体的半径, 即控制线。

2.2 监测过程

(1) 新样本监测

对于新的数据样本, 增加 l 时刻的数据, 得到其增广矩阵, 再进行加权处理后, 按照公式(5), 计算其到 SVDD 超球体球心的距离。

(2) 故障诊断

将计算的距离 D 与超球体的半径 R 进行比较, 如果 $D < R$, 则该样本正常样本, 反之, 说明此样本为故障样本。

WDSVDD 建模和在线监测具体流程见图 1。

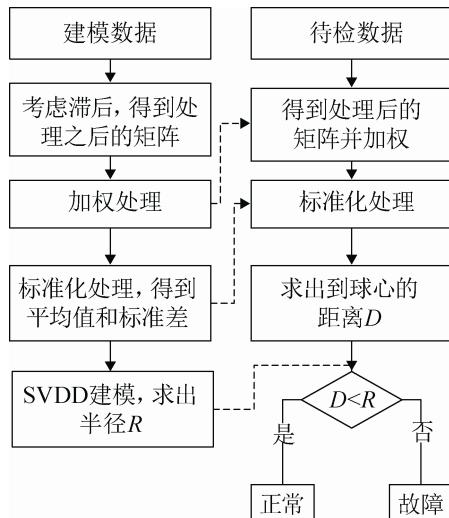


图 1 WDSVDD 建模与监测流程图

Fig. 1 WDSVDD modeling and monitoring flow chart

3 仿真实例

首先给出一个数值仿真的例子，然后又利用 TE 过程的例子进行了实验，两个例子均验证了 WDSVDD 方法的有效性、准确性。

本文采用的核函数为高斯核函数，计算公式如式(8)所示。核宽度 δ 以及惩罚系数 C 的选择均采用交叉验证的方法取得。

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|}{\delta}\right) \quad (8)$$

3.1 数值仿真

数值仿真的数据产生如式(9)所示^[12]。

$$\begin{aligned} x_1 &= t + v_1 \\ x_2 &= t^2 - 3t + v_2 \\ x_3 &= -t^3 + 3t^2(i, k) + v_3 \end{aligned} \quad (9)$$

式中： x_1, x_2, x_3 为 3 个变量， t 满足 $0.01 \sim 2$ 的均匀分布； v_1, v_2, v_3 是随机噪声，满足均值为 0、方差为 0.01 的高斯分布。一共产生包括 300 个采样点的正常数据。为了验证变量之间是否是线性关系以及每一个变量是否服从高斯分布，分别对其作正态性检验以及变量之间关系的检验，该数据 3 个变量之间的关系如图 2 所示。对每一个过程变量作正态性检验结果如图 3 所示。

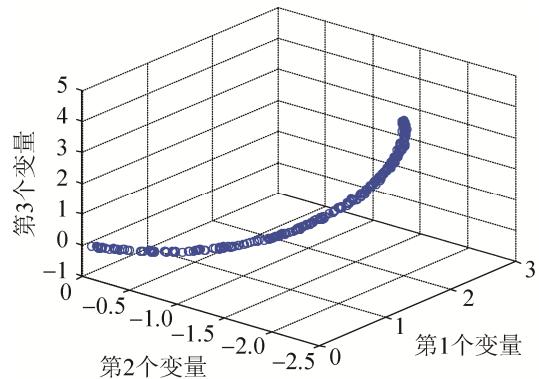


图 2 数据 3 个变量之间的关系图

Fig. 2 The relationship between the data of three variables

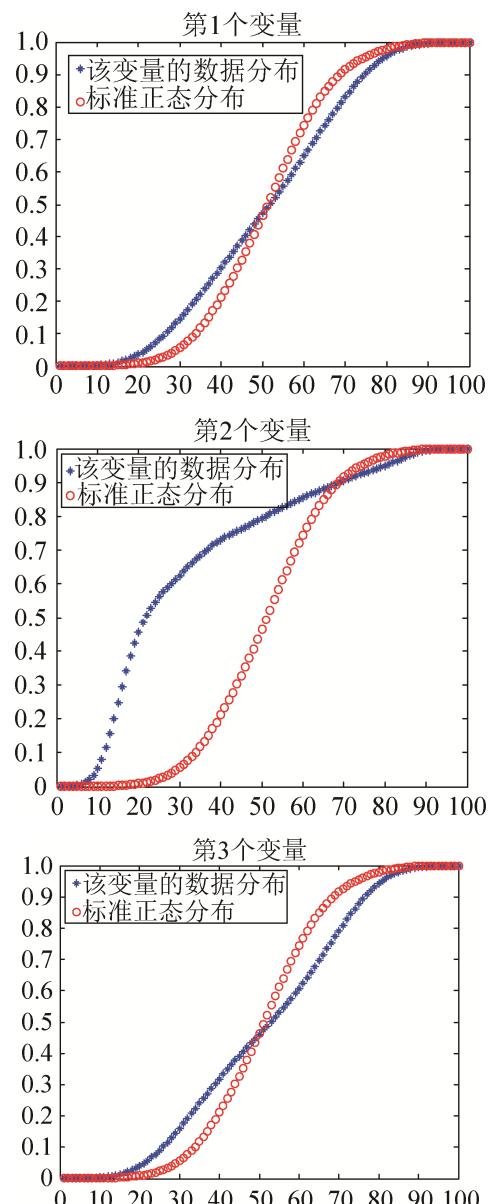


图 3 过程变量正态性检验结果

Fig. 3 Process variable normality test results

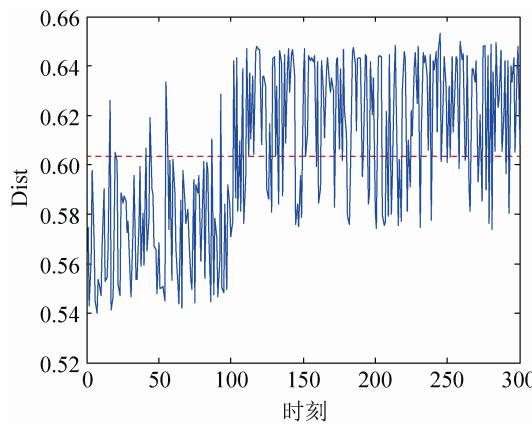
由图 2, 图 3 可以看出, 该数据 3 个变量之间的关系是非线性的, 并且数据不服从高斯分布。

为了验证所提方法的有效性, 构造两组测试数据, 并在测试数据中分别设置如下故障。

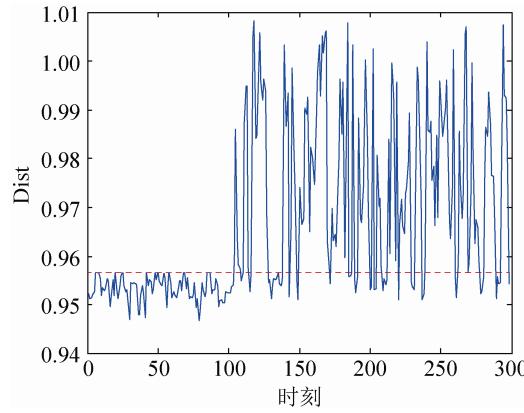
故障 1: 对变量 2 从 101 时刻开始加幅度为 -0.3 的阶跃故障。

故障 2: 对变量 1 从 101 到 270 时刻加幅度为 0.01 的斜坡故障。

分别利用 SVDD 和 WDSVDD 进行监测, 其中滞后选为 3, 结果如图 4 和图 5 所示, 其中实线代表控制限, 以下所有图均以实线作为控制限。



(a) SVDD

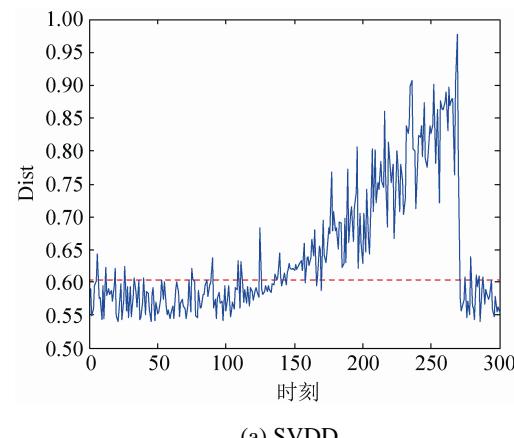


(b) WDSVDD

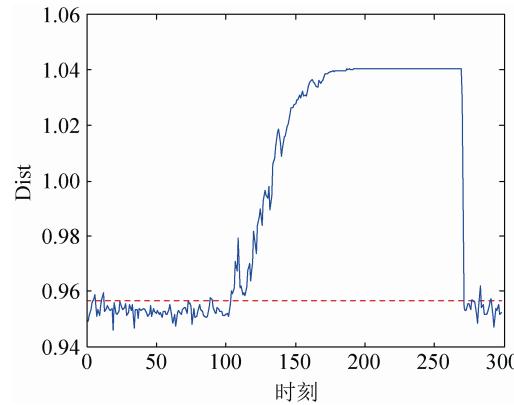
图 4 故障 1 的监测效果图
Fig. 4 The monitoring effect of Fault 1

由图 4 可以得出, 直接使用 SVDD 的故障监测率为 68.5%, 而使用 WDSVDD 方法得故障监测率可以达到 87.4%, (其中, 故障监测率为已检测出的故障时刻数与总的故障时刻数之比)。因此使

用 WDSVDD 的故障监测效果优于直接使用 SVDD 方法的效果。由图 5 可以看出对于斜坡故障使用 SVDD 方法在 140 时刻左右才能检测出系统发生了故障, 而 WDSVDD 方法在 102 时刻左右便能监测出故障, 因此 WDSVDD 的故障监测实时性更好。由此看出 WDSVDD 方法对故障更加敏感, 可以很好的提高故障监测的实时性和准确性。



(a) SVDD



(b) WDSVDD

图 5 故障 2 的监测效果图
Fig. 5 The monitoring effect of Fault 2

3.2 TE 过程

TE 过程仿真器(Tennessee Eastman Process Simulator)是由 Downs 和 Vogel 等人提出, 用来评价各种过程控制和监视方法的有效性。

本文用 TE 仿真器产生的数据, 以验证加权的动态 SVDD (WDSVDD)方法在过程监视中的应用效果^[17-18]。TE 过程包括反应器、冷凝器、气液分离器、循环压缩机和产品解析塔等 5 个主要操

作单元。该过程一共有 4 个化学反应, 生成 2 种产物, 包括 40 个测量变量和 12 个操纵变量, 即共有 52 个变量。

本文采用的建模数据为: 正常情况下, 每 3 min 采集一次样本, 一共采集 960 个样本。故障数据为: TE 过程是一个大样本的复杂非线性化工系统, 它包括 21 种预先设定好的故障, 分别代表阶跃、随机变化、慢漂移、粘滞和恒定位置等故障类型。本文一共利用了 TE 过程其中的 20 种故障, 并且都是在 161 时刻开始加入故障, 已验证所建模型的有效性。首先对每一个过程变量作正态性检验, 结果如图 6 所示。

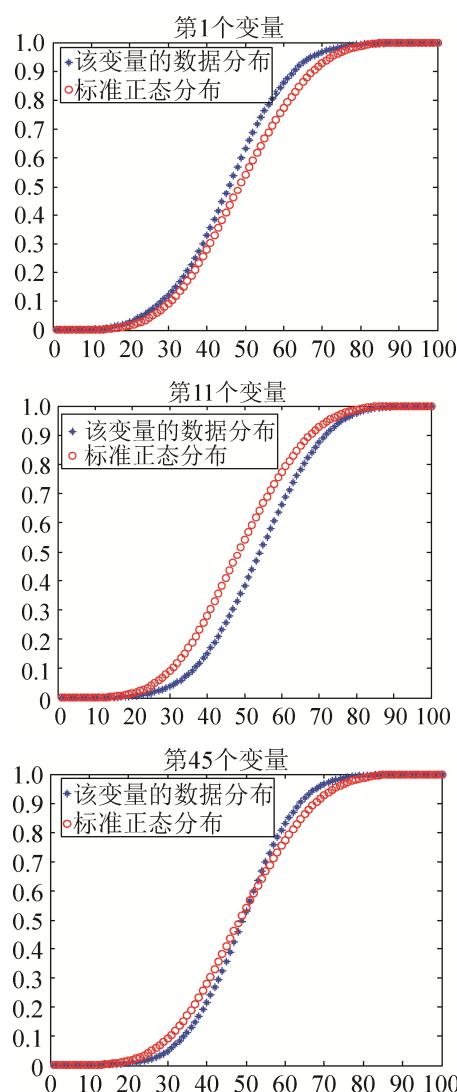


图 6 过程变量正态性检验结果
Fig. 6 Process variable normality test results

由图 6 可以看出, 数据不服从高斯分布, 同时本文列举了 TE 过程数据的第 4 种、第 11 种、第 20 种故障的监测效果, 分别如图 7~9 所示, 以第 4 种故障为例, 传统的 SVDD 方法的故障监测率为: 78.9%, 而使用 WDSVDD 方法故障监测率可以达到 99.6%。结果表明利用 WDSVDD 的监测效果相对于传统的 SVDD 方法效果更佳。为了进一步验证所建立方法的有效性, 对 TE 过程的 20 中故障, 本文一一做了监测, 结果见表 1。

由表 1 可以明显看出, WDSVDD 方法的监测效果明显优于传统的 SVDD 方法, 在非线性化工过程故障监测中准确性以及实时性更佳, 表现出了极大的优势。

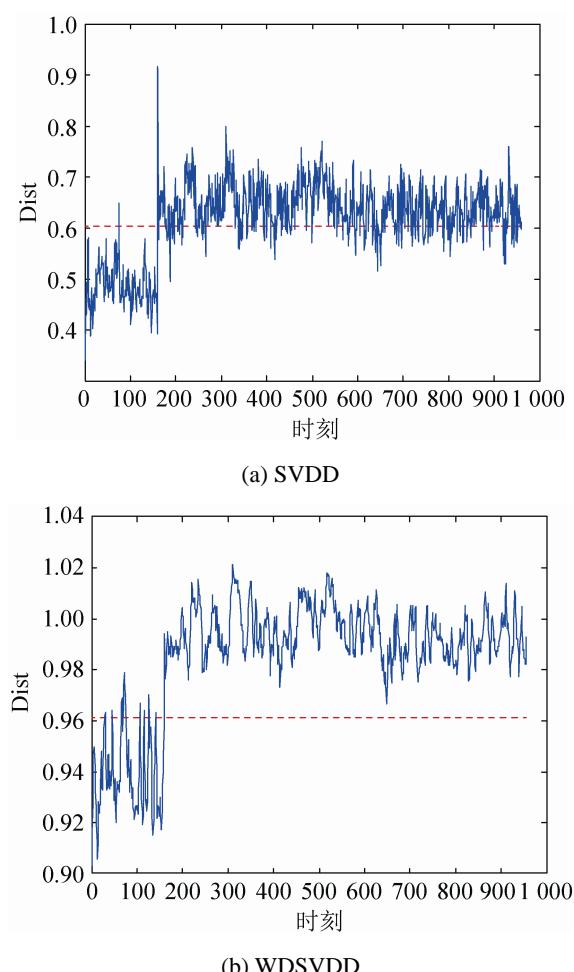


图 7 TE 过程第 4 种故障的监测效果
Fig. 7 The monitoring effect of fourth kind of fault of TE process

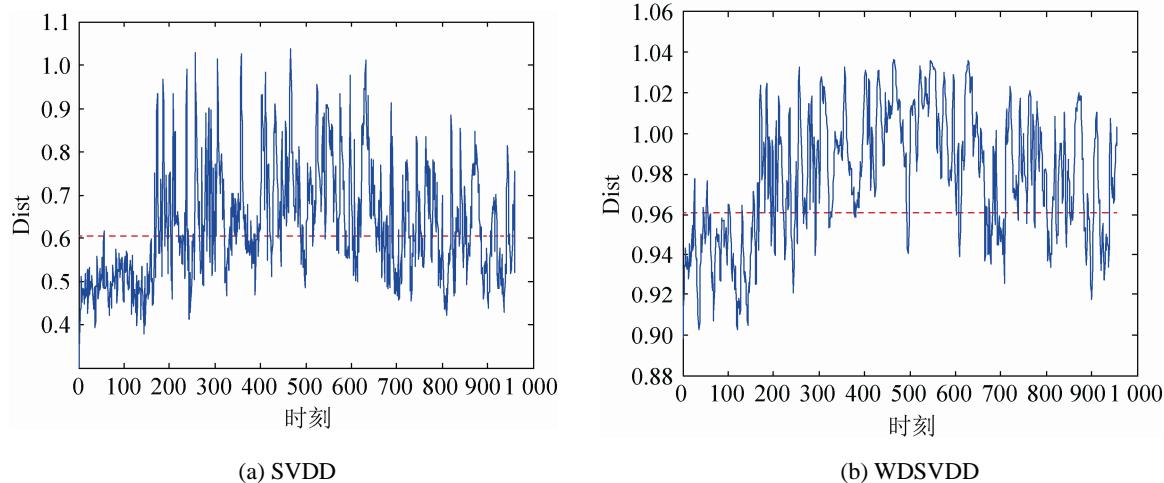


图 8 TE 过程第 11 种故障的监测效果
Fig. 8 The monitoring effect of eleventh kind of fault of TE process

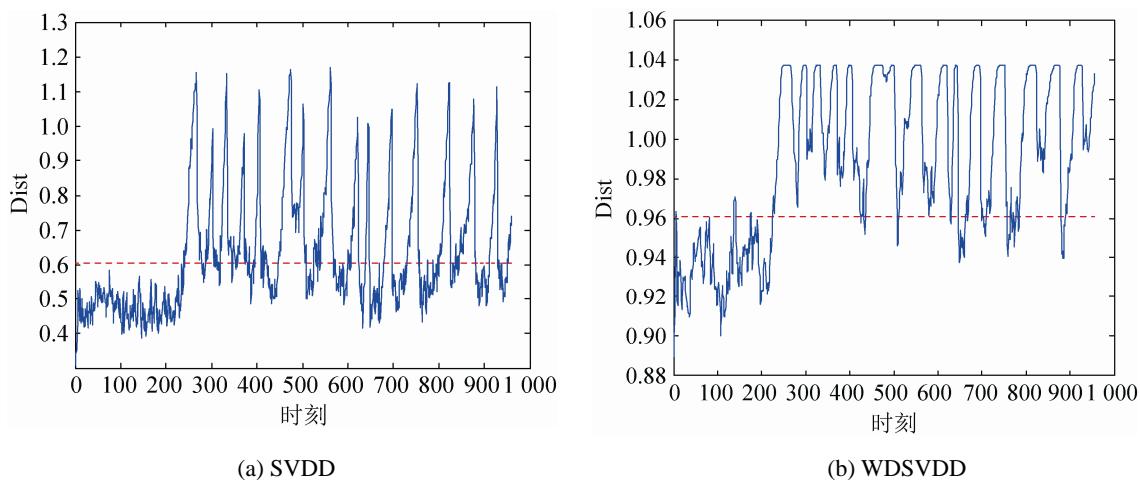


图 9 TE 过程第 20 种故障的监测效果
Fig. 9 The monitoring effect of twentieth kind of fault of TE process

表 1 TE 各个故障的监测结果
Tab. 1 TE each fault monitoring results

故障号	SVDD	WDSVDD	故障号	SVDD	WDSVDD
1	0.995	0.997	11	0.625	0.798
2	0.986	0.988	12	0.982	1.000
3	0.0750	0.262	13	0.947	0.961
4	0.789	0.996	15	0.125	0.321
5	0.311	0.586	16	0.363	0.755
7	0.821	0.871	17	0.883	0.921
8	0.973	0.980	18	0.901	0.945
9	0.073	0.125	19	0.055	0.286
10	0.536	0.812	20	0.520	0.832

4 结论

基于加权的动态 SVDD 方法是一种应用于复

杂非线性化学工业过程中具有实时在线监视的方法。该方法不仅拥有传统的 SVDD 能够克服数据服从高斯分布和不同变量之间是线性关系的限制的优点，而且考虑了某一时刻的观测数据和过去时刻的观测数据序列之间的相关性，并通过加权对有用的信息加以突出。通过将该方法应用到数值仿真、TE 过程仿真实验中，都取得了良好的效果，说明基于加权的动态 SVDD 方法改善了非线性过程在线故障监视中实时性和准确性不佳的问题。

参考文献：

- [1] 王姝, 常玉清, 王福利, 等. 时段划分的多向主元分析间歇过程监测及故障变量追溯 [J]. 控制理论与应

- 用, 2011, 28(2): 149-156. (Wang S, Chang Y Q, Wang F L, et al. Time division multi-way principal component analysis of batch process monitoring and fault variable traces [J]. Control Theory and Application, 2011, 28(2): 149-156.)
- [2] 常鹏, 王普, 高学金. 基于核熵投影技术的微生物制药生产过程监测 [J]. 信息与控制, 2014, 43(4): 490-494. (Chang P, Wang P, Gao X J. Based on the technology of nuclear entropy projection microbial pharmaceutical production process monitoring [J]. Information and Control, 2014, 43(4): 490-494.)
- [3] Hoskuldsson A. PLS regression methods [J]. J. Chemometrics (S0886-9383), 1988, 2(3): 211-228.
- [4] Nomikos P, Macgregor J F. Monitoring batch processes using multiway principal component analysis [J]. American Institute of Chemical Engineers Journal (S0096-7408), 1994, 40(8): 1361-1375.
- [5] 周东华, 李钢, 李元. 数据驱动的工业过程故障检测与诊断技术 [M]. 北京: 科学出版社, 2011. (Zhou D H, Li G, Li Y. A data-driven industrial process fault detection and diagnosis technology [M]. Beijing, China: Science Press, 2011.)
- [6] Chen J, Liu J. On-line batch process monitoring using dynamic PCA and dynamic PLS models [J]. Chemical Engineering Science (S0009-2509), 2002, 57(1): 63-75.
- [7] Choi S W, Lee I B. Nonlinear dynamic process monitoring based on dynamic kernel PCA [J]. Chemical Engineering Science (S0009-2509), 2004, 59(24): 5897-5908.
- [8] Qin J S. Survey on data-driven industrial process monitoring and diagnosis [J]. Annual Reviews in Control (S1367-5788), 2012, 36(2): 220-234.
- [9] Lee J M, Yoo C, Lee I B. Fault detection of batch processes using multiway kernel principal component analysis [J]. Comput Chem Eng (S0098-1354), 2004, 28(9): 1837-1847.
- [10] 赵春晖, 王福利, 姚远, 等. 基于时段的间歇过程统计建模、在线监测及质量预报 [J]. 自动化学报, 2010, 36(3): 366-374. (Zhao C H, Wang F L, Yao Y, et al. Based on statistical modeling of batch processes during online monitoring and quality prediction [J]. Acta Automatica Sinica, 2010, 36(3): 366-374.)
- [11] Lennox B, Montague G A, Hiden H G, et al. Process monitoring of an industrial fed-batch fermentation [J]. Biotechnology and Bioengineering (S0006-3592), 2001, 74(2): 125-135.
- [12] Ge Z Q, song Z H. Performance-driven ensemble learning ICA model for improved non-Gaussian process monitoring [J]. Chemometrics and Intelligent Laboratory Systems (S0169-7439), 2013, 123(15): 1-8.
- [13] Ge Z Q, Gao F R, Song Z H. Batch Process monitoring based on support vector data description method [J]. Journal of Process Control (S0959-1524), 2011, 21(6): 949-959.
- [14] Tax D M J, Duin R P W. Support vector domain description [J]. Pattern Recognition Letters (S0167-8655), 1999, 20(11/13): 1191-1199.
- [15] Tax D M J, Duin R P W. Support vector domain description [J]. Machine Learning (S0885-6125), 2004, 54(1): 45-66.
- [16] 谢彦红, 耿志成, 李元. SVDD 在间歇过程监测中的应用研究 [J]. 计算机与应用化学, 2013, 30(12): 1401-1405. (Xie Y H, Geng Z C, Li Y. SVDD application in batch process monitoring research [J]. Computer and Applied Chemistry, 2013, 30(12): 1401-1405.)
- [17] 谢彦红, 孙呈敖, 李元. 基于滑动窗口 SVDD 的间歇过程故障监测 [J]. 信息与控制, 2015, 44(5): 531-537. (Xie Y H, Sun C A, Li Y. Based on sliding window SVDD fault monitoring of batch process [J]. Information and Control, 2015, 44(5): 531-537.)
- [18] 罗刚, 张湜, 牛彦杰. 基于 TE 过程的仿真系统的实现 [J]. 南京工业大学学报(自然科学版), 2005, 27(3): 77-80. (Luo G, Zhang D, Niu Y J. The realization of the simulation system based on TE process [J]. Journal of Nanjing University of Technology (Natural Science Edition), 2005, 27(3): 77-80.)