

# 稀疏性 SVDD 方法在故障检测中的应用研究

王国柱<sup>1</sup>, 刘建昌<sup>1</sup>, 李元<sup>2</sup>

(1. 东北大学 信息科学与工程学院, 辽宁 沈阳 110819; 2. 沈阳化工大学 信息工程学院, 辽宁 沈阳 110142)

**摘 要:** 在支持向量数据描述(SVDD)方法的基础上,通过研究原始正常数据分布在高维映射空间内的稀疏特性,选取前  $k$  个高维分布边缘的数据点进行 SVDD 建模,用于解决 SVDD 方法处理大样本数据的缺陷,以及建模与过程监视时间长的的问题.经过理论推导和仿真分析,验证了稀疏性 SVDD 建模方法可以有效地提高建模以及过程检测速度;对于大样本数据可以利用筛选后的小样本进行建模,解决了 SVDD 方法不能很好地处理大样本数据分类的问题;同时,此方法不影响故障检测的精度.在 TE 过程中的应用验证了该方法的有效性.

**关 键 词:** 稀疏性;SVDD;稀疏性 SVDD;故障检测

中图分类号: TP 274

文献标志码: A

文章编号: 1005-3026(2015)06-00761-05

## An Applied Research of Sparsity SVDD Method to the Fault Detection

WANG Guo-zhu<sup>1</sup>, LIU Jian-chang<sup>1</sup>, LI Yuan<sup>2</sup>

(1. School of Information Science & Engineering, Northeastern University, Shenyang 110819, China;  
2. Information Engineering School, Shenyang University of Chemical Technology, Shenyang 110142, China.  
Corresponding author: WANG Guo-zhu, E-mail: wang.guo.zhu@163.com)

**Abstract:** Fault detection based on the basic SVDD (support vector data description) method is not good at the processing of large sample data, and the modeling and process monitoring is time-consuming. The sparse characteristics of the original data in high dimension space was studied, according to which the first  $k$  high dimensional distribution edge data points were selected to carry out the SVDD modeling. Through theoretical derivation and simulation analysis, it was showed that the modeling and detection speed could be effectively improved by the proposed method, and the large sample data could be modeled by using the selected small sample, which could handle the classification problems of SVDD method on solving large sample data; meanwhile, this method did not affect the accuracy of fault detection. The effectiveness of the proposed method was illustrated by applying it to the monitoring of TE process.

**Key words:** sparsity; SVDD; sparsity SVDD; fault detection

故障检测的实质可以用数据分类的问题来描述,通常数据可以分为正常(目标)样本与非正常(非目标)样本,在实际生产过程中,得到正常状态下的过程数据是很容易的,运用所获得的正常数据来对实时数据进行监视,是数据驱动故障检测的重要手段<sup>[1]</sup>. SVDD 方法是一种利用最小封闭球体与支持向量理论进行数据描述的方法,此方法与支持向量机类似,是一种针对小样本的学

习理论<sup>[2-3]</sup>,其主要思想是通过寻找数据集最小边缘半径的超球体,使其能够尽可能包含所有的同类数据,排除非同类数据,达到数据合理分类的目的.该方法是一种新的单值分类方法,可以运用于工业过程故障检测.因此,可以利用正常数据建立 SVDD 模型,求取模型控制限并对新的过程采样进行检测,实现过程监视的目的.

本文在 SVDD 算法的基础上,提出一种稀疏

收稿日期: 2014-04-22

基金项目: 国家自然科学基金资助项目(61374137,61174119,61034006,60774070); 流程工业综合自动化国家重点实验室基础科研业务费资助项目(2013ZCX02-03).

作者简介: 王国柱(1984-),男,河南焦作人,东北大学博士研究生;刘建昌(1960-),男,辽宁沈阳人,东北大学教授,博士生导师;李元(1964-),女,辽宁沈阳人,沈阳化工大学教授,博士生导师.

性 SVDD(S-SVDD)建模方法,用于解决前者不能较好地处理大样本数据缺陷的问题. 经过理论推导与仿真实验,验证了此方法可以有效地应用于工业过程故障检测.

## 1 SVDD 方法与稀疏性理论介绍

SVDD 理论上要求一个包含所有目标数据的尽可能小的球体,与 SVM<sup>[4]</sup>类似,这个球体由少部分支持向量决定. 对于一个有限数据集,支持向量是位于高维数据分布边缘的少量样本,SVDD<sup>[3,5]</sup>根据结构风险最小化原理,通过求取一个尽可能少的包含奇异点数据,并且体积最小的球体来描述样本数据,即求满足一定条件的半径为  $R$  和球心为  $a$  的球体. 此方法适用于处理非线性与非高斯数据<sup>[6]</sup>.

### 1.1 支持向量数据描述 (SVDD)

为建立一个非线性数据模型,SVDD 方法首先通过一个非线性变换  $\mathcal{R}: x \rightarrow F$  将原始正常数据  $X = \{x_i \in \mathbf{R}^d, i = 1, 2, \dots, n\}$  映射到一个高维特征空间;其次,在特征空间中寻找一个最小体积的球体并使其包含所有的高维空间数据点. SVDD 求取最小超球体的实质就是求解以下最优化问题<sup>[1]</sup>:

$$\min_{R, a, \xi} R^2 + C \sum_{i=1}^n \xi_i.$$

$$\text{s. t. } \|\mathcal{R}(x_i) - a\|^2 \leq R^2 + \xi_i, \forall i, \xi_i \geq 0. \quad (1)$$

其中: $a$  是球心; $C$  是控制球体体积和误差的折中常数; $\xi_i$  为允许范围误差的松弛变量. 可以将式(1)的最小化问题转化为其对偶问题的最大化问题<sup>[1]</sup>:

$$L = \sum_i \alpha_i (x_i, x_i) - \sum_{i,j} \alpha_i \alpha_j (x_i, x_j). \\ \text{s. t. } \sum_i \alpha_i = 1, 0 \leq \alpha_i \leq C. \quad (2)$$

在式(2)中,内积可以用高斯核函数<sup>[7]</sup>来代替求解:

$$k(x_i, x_j) = \exp(-\|x_i - x_j\|^2 / s^2). \quad (3)$$

将式(3)代入式(2),可以得到

$$L = \sum_i \alpha_i k(x_i, x_i) - \sum_{i,j} \alpha_i \alpha_j k(x_i, x_j). \\ \text{s. t. } \sum_i \alpha_i = 1, 0 \leq \alpha_i \leq C. \quad (4)$$

根据上面分析求取使  $L$  最小值情况下的最优解  $\alpha_i$ ,可以表现为以下三种情况( $x_{sv}$  为支持向量):

$$\left. \begin{aligned} \alpha_i &= 0; x_i \in x_{sv}, \\ \alpha_i &= C; x_i \notin x_{sv}, \\ 0 &< \alpha_i < C; x_i \in x_{sv}. \end{aligned} \right\} \quad (5)$$

当  $\alpha_i = 0$ ,数据点在球体内;当  $\alpha_i = C$ ,数据点在球体外;当  $0 < \alpha_i < C$ ,数据点在超球体表面上.

超球体的球心  $a$  与半径  $R$  分别为<sup>[8-9]</sup>

$$a = \sum_i \alpha_i x_{sv_i}, \\ R = (x_{sv_c} \cdot x_{sv_c}) - 2 \sum_i \alpha_i (x_{sv_i} \cdot x_{sv_c}) + \\ \sum_i \sum_j \alpha_i \alpha_j (x_{sv_i} \cdot x_{sv_j}). \quad (6)$$

对于新采样的无故障数据只需满足以下条件:

$$k(x_{\text{new}}, x_{\text{new}}) - 2 \sum_{i=1}^n \alpha_i k(x_{\text{new}}, x_i) + \\ \sum_{i=1}^n \alpha_i \alpha_j k(x_i, x_j) \leq R^2. \quad (7)$$

### 1.2 数据点的稀疏性

连续过程采集到的数据点具有一定的稀疏性,并且它们之间的距离通常具有相似性,当把数据映射到高维特征空间后,数据点之间稀疏程度会更加明显.

一个高维数据点  $x$  的稀疏度定义如下:

$$\delta(x) = \exp\left(\frac{1}{n} \sum_{i=1}^n \|\mathcal{R}(x) - \mathcal{R}(x_i)\|^2 / D\right). \quad (8)$$

其中:

$$\|\mathcal{R}(x) - \mathcal{R}(y)\|^2 = k(x, x) + k(y, y) - \\ 2k(x, y) = 2 - 2k(x, y), \quad (9)$$

$k(x, y)$  为高斯核函数.

$$D = \frac{1}{n} \sum_{j=1}^n (1/n \sum_{i=1}^n \|\mathcal{R}(x_j) - \mathcal{R}(x_i)\|^2). \quad (10)$$

**定理:**样本点  $x$  的稀疏度越大,其在高维空间中距离 SVDD 球心的距离越远.

假设原始数据中有两个样本点  $x_1$  与  $x_2$ ,并且

$$\delta(x_1) > \delta(x_2). \quad (11)$$

$$\Leftrightarrow \exp\left(\frac{1}{n} \sum_{i=1}^n \|\mathcal{R}(x_1) - \mathcal{R}(x_i)\|^2 / D\right) >$$

$$\exp\left(\frac{1}{n} \sum_{i=1}^n \|\mathcal{R}(x_2) - \mathcal{R}(x_i)\|^2 / D\right). \quad (12)$$

$$\Leftrightarrow \sum_{i=1}^n \|\mathcal{R}(x_1) - \mathcal{R}(x_i)\|^2 >$$

$$\sum_{i=1}^n \|\mathcal{R}(x_2) - \mathcal{R}(x_i)\|^2. \quad (13)$$

$$\Leftrightarrow \sum_{i=1}^n (2 - 2k(x_1, x_i)) > \sum_{i=1}^n (2 - 2k(x_2, x_i)). \quad (14)$$

$$\Leftrightarrow \sum_{i=1}^n k(x_1, x_i) < \sum_{i=1}^n k(x_2, x_i). \quad (15)$$

$$\Leftrightarrow \sum_{i=1}^n \alpha_i k(x_1, x_i) < \sum_{i=1}^n \alpha_i k(x_2, x_i). \quad (16)$$

由于  $\sum_{i=1}^n \alpha_i \alpha_j k(x_i, x_j)$  为常数,因此

$$1 - 2 \sum_{i=1}^n \alpha_i k(x_1, x_i) + \sum_{i=1}^n \alpha_i \alpha_j k(x_i, x_j) >$$

$$1 - 2 \sum_{i=1}^n \alpha_i k(x_2, x_i) + \sum_{i=1}^n \alpha_i \alpha_j k(x_i, x_j). \quad (17)$$

$$\Leftrightarrow \| \mathcal{R}(x_1) - a \|^2 > \| \mathcal{R}(x_2) - a \|^2. \quad (18)$$

2 S - SVDD 建模方法

SVDD 超球体是利用在所有样本中选取的支持向量来建立的,因此在建模之前要对所有数据点进行预判断,找出支持向量. 对大样本数据而言,这样会经过很多不必要的步骤,既影响建模速度,又对建模精度不利. 而在实际工业过程中,数据收集量往往非常庞大,为了及时检测到系统中是否存在故障,建模以及检测时间在一定程度上起到了关键作用. 本文提出的 S - SVDD 方法是在数据稀疏度的基础上,选择稀疏度大的局部数据(超球体外层数据)样本进行 SVDD 超球体建模,可以弥补 SVDD 方法的不足.

S - SVDD 建模及检测步骤如下:首先,对训练样本集合  $X = \{x_i \in R^d, i = 1, 2, \cdots, n\}$ , 根据 1.2 节求取各个采样时刻数据的稀疏度  $\delta(x_i)$ ;第二,选择稀疏度大的前  $k$  个采样数据,并利用这些数据建立 SVDD 模型,求取超球体球心、半径;第三,对于新的采样数据,根据式(7)计算其到球心的距离  $D_{\text{new}}$ ,  $D_{\text{new}} < R$  为正常采样,否则发生故障.

3 仿真实验

TE 过程由压缩机、分离器、反应器、冷凝器和汽提塔 5 个主要的操作单元组成,包括 A ~ H 8 种成分,过程中有 41 个测量变量和 12 个控制变量. 详细描述与工艺流程参见文献[10 - 12]. 仿真实验选取 22 个测量变量和 11 个控制变量作为监测样本集,数据通过仿真软件获得. 各个工况的采样间隔均为 3 min,每次运行时间为 48 h,仿真开始时系统处于正常状态,在 8 h 时引入故障. 正常工况的 960 个样本采自过程平稳运行状态,各故障工况前 160 个时刻为无故障样本,后 800 个时刻为故障样本. TE 过程共有 21 种故障,表 1 对其中的故障 f2, f4, f13, f14 进行了详细的描述. 为了比较两种方法的仿真结果,其参数设置见表 2.

表 1 TE 过程故障描述  
Table 1 Faults description of TE process

故障	故障类型	过程变量
f2	阶跃	流量 4 中 B 变化, A/C 恒定
f4	阶跃	反应器冷却水入口温度
f13	缓慢漂移	反应动态
f14	粘住	反应器冷却水阀门

首先对正常过程的 960 个样本进行标准化处

理,使用传统 SVDD 方法进行建模,计算正常状态的球心  $a$  和半径  $R$ , 分别对 21 组故障数据进行监视,找到故障发生时刻,部分检测结果如图 1 所示.

表 2 两种方法的参数设置  
Table 2 Parameters of two methods

方法	核参数 $s$	调整参数 $C$	选择样本数 $k$
SVDD	10	1	960
S - SVDD	10	1	100




图 1 SVDD 方法的故障检测结果  
Fig. 1 Fault detection results using SVDD method  
(a) — f2; (b) — f4; (c) — f13; (d) — f14.

根据原始正常数据分布在高维映射空间内的稀疏特性,选取前 100 个高维分布边缘的数据点进行 S-SVDD 建模,找到最优的球心  $a$  和半径  $R$ ,并求取新的采样数据距离球心  $a$  的距离,对应检测结果见图 2。




图2 S-SVDD 方法的监视结果

Fig. 2 Fault detection results using S-SVDD method

(a)—f2; (b)—f4; (c)—f13; (d)—f14.

从 TE 过程故障 f2, f4, f13 和 f14 的检测结果可以看出:两种方法都可以及时检测到故障以及确定故障的发生时刻,但对比二者的建模与各个故障的检测时间, S-SVDD 方法有明显的改善.具体建模及检测各故障情况耗时见表 3。

表 3 对 4 种故障的定量分析比较  
Table 3 Comparison of quantitative analysis on the four kind of faults

方法	建模 $t$	建模 样本数	f2	f4	f13	f14
SVDD	2.49	960	4.90	4.87	4.92	4.89
S-SVDD	0.012	100	2.43	2.43	2.42	2.42

## 4 结 论

本文引入数据分布在高维映射空间内的稀疏性,并根据此特性选取前  $k$  个高维分布边缘的数据点进行 S-SVDD 建模,经过理论推导和仿真,验证了 S-SVDD 建模方法可以有效地提高建模和过程检测速度,减少冗余计算量;对样本量较大的数据集可以利用筛选后的小样本建模,在一定程度上改善了 SVDD 方法处理大样本数据计算耗时的问题。

## 参考文献:

- [1] 谢磊,刘雪芹,张健明,等. 基于 NGPP-SVDD 的非高斯过程监控及其应用研究[J]. 自动化学报, 2009, 35(1): 107-112. (Xie Lei, Liu Xue-qin, Zhang Jian-ming, et al. Non-Gaussian process monitoring based on NGPP-SVDD [J]. *Acta Automatica Sinica*, 2009, 35(1): 107-112.)
- [2] Vapnik V N. 统计学习理论[M]. 北京: 电子工业出版社, 2004. (Vapnik V N. *Statistical learning theory* [M]. Beijing: Electronic Industry Press, 2004.)
- [3] Tax D, Duin R. Support vector data description[J]. *Machine Learning*, 2004, 54(1): 45-66.
- [4] Vapnik V N. *The nature of statistical learning theory* [M]. New York: Springer-Verlag, 1995.
- [5] Tax D. One-class classification [M]. Delft: Delft University of Technology, 2001: 21-55.
- [6] Ge Z Q, Gao F, Song Z H. Batch process monitoring based on support vector data description method [J]. *Journal of Process Control*, 2011, 21: 949-959.
- [7] Saitoh S. *Theory of reproducing kernels and its applications* [M]. Harlow: Longman Scientific & Technical, 1998.
- [8] Asa B H, David H, Siegelmann H T, et al. Support vector clustering[J]. *Journal of Machine Learning Research*, 2001, 2: 125-137.
- [9] Wang X M, Chung F L, Wang S T. Theoretical analysis for solution of support vector data description [J]. *Neural Networks*, 2011, 24: 360-369.

(下转第 768 页)