

DOI: 10.11830/ISSN.1000-5013.201707056



多变量过程监控的 D 控制图

夏蓓鑫¹, 简铮², 高雅², 陶宁蓉³

(1. 上海大学 管理学院, 上海 200444;

2. 上海大学 机电工程与自动化学院, 上海 200072;

3. 上海海洋大学 工程学院, 上海 201306)

摘要: 针对如何将大数据技术与传统的多元控制图相结合,以获得一个具有自学习性的控制图的问题,以支持向量数据描述(SVDD)为构建基础,提出一个基于支持向量数据描述的 D 控制图.该 D 控制图通过对在控数据的学习,自适应地构建出自己的监控模型.仿真实验及工业实例表明: D 控制图在多变量制造过程中的表现优于 T^2 控制图,是一个理想的监控模型.

关键词: D 控制图;多元统计过程控制;支持向量数据描述;平均运行链长

中图分类号: TP 206.3; O 213.1

文献标志码: A

文章编号: 1000-5013(2018)06-920-06

D Control Chart for Multivariable Process Monitoring

XIA Beixin¹, JIAN Zheng², GAO Ya², TAO Ningrong³

(1. School of Management, Shanghai University, Shanghai 200444, China;

2. School of Mechatronics Engineering and Automation, Shanghai University, Shanghai 200072, China;

3. College of Engineering, Shanghai Ocean University, Shanghai 201306, China)

Abstract: For the issue of how to combine the big data technology with the traditional multivariate control chart to get a control chart with self-learning. Based on support vector data description (SVDD), a D control chart with SVDD is proposed in this paper. The D control chart can adaptively construct its own monitoring model through being trained by the in-control data. Simulation results and industrial examples show that the D control chart has a better performance compared with the T^2 control chart for the multivariable manufacturing process, and it is a promising monitoring model.

Keywords: D control chart; multivariate statistical process control; support vector data description; average run length

在现代化工业制造过程中,一个完整的制造单元常由多个相关变量组成,如果分别使用单变量控制图进行监控往往效果不好^[1].因此,针对具有互相关性的多变量制造,提出相应的多变量控制图尤为重要. Hotelling 最早注意到这个问题,并提出 T^2 控制图监控多变量制造过程^[2].之后,由于 T^2 控制图对小幅度异常的不敏感性^[3],研究人员又提出多元累积和控制图^[4]及多元指数加权移动平均控制图^[5].这些控制图基于传统的数理统计方法,缺乏自学习性.随着传感器技术的进步,越来越多的传感器被安装在制造过程的各个环节,以收集制造过程的多方位信息.随着人工智能技术的进步,许多具有自学习性的机器学习算法被提出.例如,支持向量机(SVM)^[6]、支持向量数据描述(SVDD)^[7-8]、反向传播(BP)神

收稿日期: 2017-07-22

通信作者: 夏蓓鑫(1984-),男,讲师,博士,主要从事质量管理、可靠性工程的研究. E-mail: bxxia@shu.edu.cn.

基金项目: 国家自然科学基金资助项目(71401098);上海市高校青年教师培养资助计划(ZZSD15047)

神经网络^[9]、自组织特征映射(SOM)神经网络^[10]等.在大数据时代的背景下,将一些机器学习算法与传统控制理论相结合,以克服传统多元控制图的缺陷,使新的控制图具有自学习^[11].文献[12]将无监督学习的 SOM 神经网络作为学习器,学习在控数据分布,基于训练好的 SOM 神经网络结构,构建最小量化误差(MQE)控制图.这样的构建方式使 MQE 控制图具有良好的自学习性.但其构建的基础为 SOM 神经网络,而支持向量数据描述是一个更好的选择.因此,本文提出一个基于支持向量数据描述的 D 控制图,用于监控多变量制造过程.

1 T^2 控制图

在化学工业和过程工业生产中,往往需要同时监测多个质量特性,且这些质量特性具有一定的相关性.假设观测值 $\mathbf{X}=[x_1,x_2,\cdots,x_p]'$ 服从 p 元正态分布 $N(\mu_0,\boldsymbol{\Sigma})$, T^2 控制图的统计量定义为

$$T^2=(\mathbf{X}-\mu_0)^r\boldsymbol{\Sigma}^{-1}(\mathbf{X}-\mu_0). \tag{1}$$

T^2 控制图的控制限 h 是由在控平均运行链长(ARL)决定的.当统计量 $T^2>h$,可认为该制造过程失控;否则,认为过程受控.

2 基于支持向量数据描述的 D 控制图

2.1 支持向量数据描述

支持向量数据描述是一种一类分类器,能解决一分类问题.它的目标是找到一个最小的超球体,把大部分目标集的数据包含在里面.一个典型的描述过程,如图 1 所示.图 1 中: x_1,x_2 为样本对应的坐标位置值.

当给定一个训练的目标集 $T=\{\mathbf{x}_i\in\mathbf{R}^d,i=1,\cdots,N\}$, N 为目标集的数量, \mathbf{x}_i 为一个 d 维的向量.构建包含目标集的最小超球体的数学过程,有

$$\max L=\sum_i a_i K(\mathbf{x}_i\cdot\mathbf{x}_i)-\sum_{i,j} a_i a_j K(\mathbf{x}_i\cdot\mathbf{x}_j). \tag{2}$$

式(2)中: $K(\mathbf{x}_i\cdot\mathbf{x}_j)$ 为核函数; $\sum_i a_i=1, 0\leq a_i\leq C, i,j=1,\cdots,N$.

一般主要使用的核函数有 2 种:高斯核函数和多项式核函数.由于高斯核函数在数据描述方面具有更好的表现^[13],故采用高斯核函数进行控制图的构建,即

$$K(\mathbf{x}_i,\mathbf{x}_j)=\exp\left(-\frac{\|\mathbf{x}_i-\mathbf{x}_j\|^2}{s^2}\right). \tag{3}$$

式(3)中: s 为核函数.

在支持向量数据描述中,惩罚参数 C 、核函数 s 是 2 个重要的参数,分别选取 C 为 5, s 为 1^[14-15].

2.2 D 控制图

2.2.1 D 统计值 基于支持向量数据描述的 D 控制图的监控统计量为 D ,其计算公式为

$$D=\|\mathbf{t}-\mathbf{a}\|^2=K(\mathbf{t}\cdot\mathbf{t})-2\sum_i a_i K(\mathbf{t}\cdot\mathbf{x}_i)+\sum_{i,j} a_i a_j K(\mathbf{x}_i\cdot\mathbf{x}_j). \tag{4}$$

式(4)中: \mathbf{t} 为输入的向量数据,输入数据是通过移动窗口法得到的数据; \mathbf{a} 为支持向量数据描述学习到的超空间的中心.

2.2.2 移动窗口分析法 采用移动窗口的方法获得监控数据,一个简单的应用过程,如图 2 所示.图 2 中: N 为观测的个体.因为不同的窗口大小会使控制图获得不同的监控性能,所以窗口大小的选择需要进一步分析.

2.2.3 基于 D 控制图的监控模型 支持向量数据描述在离线过程通过对在控目标数据集进行离线学习,学习到在控数据的空间分布.在在线监控阶段,可以利用 D 值判断当前制造过程的状态.

如果 $D>h$,则控制图发出报警,表示当前制造过程超控, h 可以通过给定的在控 ARL 调整得到. D 控制图的一个典型的监控模型,如图 3 所示.




图 1 支持向量数据描述的数据描述过程
Fig. 1 Data description process of SVDD




图 2 移动窗口
Fig. 2 Moving window

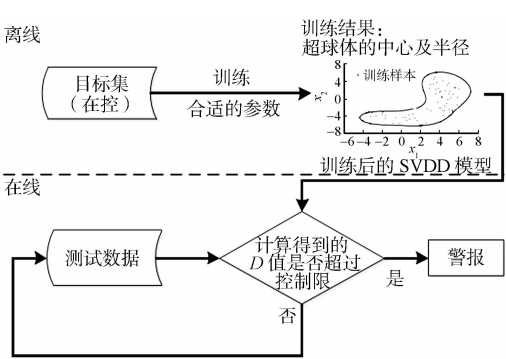


图 3 D 控制图的监控模型
Fig. 3 Monitoring model of D control charts

3 仿真实验

3.1 窗口大小的影响

为了研究窗口大小对 D 控制图监控性能的影响,分别选取 25,16,12,4 的窗口进行仿真实验,以选择合适的窗口大小. 离线学习数据集不是原始二维正态分布数据,而是 T^2 统计值^[2]. 前期基础性的实验证明这样的构建方法能够使控制图有更好的监控性能.

首先,产生二维正态分布(均值为 $\begin{bmatrix} 0 \\ 0 \end{bmatrix}$,协方差矩阵为 $\begin{bmatrix} 1.0 & 0.8 \\ 0.8 & 1.0 \end{bmatrix}$)的在控仿真数据. 同时,计算每个数据点的 T^2 统计值. 然后,通过移动窗口法采集 1 000 组 n 维的在控学习数据集, n 为移动窗口大小,将 1 000 组数据集输入 SVDD 进行离线学习. 完成离线学习后,通过调节控制限 h ,使在控 ARL 大约等于设定值. 本次实验中,设定值为 380. 获得控制限 h 后,生成超控数据,即

$$\mathbf{X}_t = \mathbf{Y}_t + \boldsymbol{\delta}, \quad t \geq n. \tag{5}$$

式(5)中: \mathbf{Y}_t 为 t 时刻的在控数据; \mathbf{X}_t 为 t 时刻的超控数据; $\boldsymbol{\delta}$ 为阶跃向量, $\boldsymbol{\delta} = \begin{bmatrix} \delta_1 \\ \delta_2 \end{bmatrix}$; n 为窗口大小.

计算每个数据点的 T^2 统计值. 同样采用移动窗口的方法获得 1 000 组 n 维超控数据,计算超控 ARL. 用马氏距离 λ 表示阶跃幅度的大小^[16],即

$$\lambda = \sqrt{\boldsymbol{\delta}^T \boldsymbol{\Sigma}^{-1} \boldsymbol{\delta}}. \tag{6}$$

式(6)中: $\boldsymbol{\Sigma}$ 为协方差矩阵.

一般而言,一个大的阶跃幅度会得到一个小的在控 ARL. 因此,根据 λ 对结果进行排序,以获得更好的展示效果. 选取 7 个不同程度的阶跃幅度向量 $\boldsymbol{\delta}$ 作为实验对象, $\boldsymbol{\delta} = \begin{bmatrix} 0.75 \\ 0.00 \end{bmatrix}, \begin{bmatrix} 1.00 \\ 0.25 \end{bmatrix}, \begin{bmatrix} 1.50 \\ 1.50 \end{bmatrix}, \begin{bmatrix} 1.50 \\ 0.50 \end{bmatrix},$

$$\begin{bmatrix} 1.50 \\ 2.00 \end{bmatrix}, \begin{bmatrix} 2.50 \\ 0.25 \end{bmatrix}, \begin{bmatrix} 2.50 \\ 0.25 \end{bmatrix}.$$

在控 ARL 及超控 ARL 都是通过 10 000 次实验得出的结果,实验结果如图 4 所示. 由图 4 可知:窗口大小为 4 的情况下,相较于其他窗口,其整体的监控性能明显较差;虽然在小的阶跃幅度时,窗口 25 的监控性能最好,但在大的阶跃幅度时,窗口 4 的监控性能最好. 因此,窗口 16 是一个最好的选择,可以获得整体最优的监控性能.

3.2 性能分析

对仿真实验进行对比,验证 D 控制图的监控性能. 实验假设数据集都服从均值为 $\begin{bmatrix} 0 \\ 0 \end{bmatrix}$,协方差矩阵




图 4 不同窗口大小仿真结果
Fig. 4 Simulation results of different window sizes

为 $\begin{bmatrix} 1.0 & 0.8 \\ 0.8 & 1.0 \end{bmatrix}$ 的二维正态分布.

在离线学习阶段,将采集到的 1 000 组 16 维在控数据集的 T^2 统计值输入 SVDD 进行离线训练,获得训练后的 SVDD 结构. 调节控制限 h ,使在控 ARL 大约等于设定值 370. 在在线监控过程中,通过不同的阶跃向量 δ 生成不同超控程度的超控数据,并计算相应的超控 ARL. 同时,用表示阶跃幅度的 λ 进行排序. D 控制图($h=1.037\ 26$)和 T^2 控制图($h=11.831\ 5$)的 ARL 性能,如表 1 所示.

表 1 控制图的 ARL 性能仿真结果

Tab. 1 ARL performance simulation results for control charts

实验序号	λ	δ	超控 ARL(D 控制图)	超控 ARL(T^2 控制图)
0	0	(0,0)	373.613 8	370.837 4
1	0.263 5	(0.25,0.25)	271.873 2	290.043 4
2	0.416 7	(0.25,0.00)	193.310 1	233.862 0
3	0.527 0	(0.50,0.50)	143.242 3	192.179 1
4	0.559 0	(0.50,0.25)	129.911 4	176.870 2
5	0.768 3	(0.75,0.50)	68.973 0	114.131 6
6	0.790 6	(0.75,0.75)	64.315 8	106.988 9
7	0.833 3	(0.50,0)	56.365 2	97.643 7
8	0.950 1	(0.75,0.25)	40.214 4	76.506 5
9	1.003 5	(1.00,0.75)	34.778 6	67.853 8
10	1.054 1	(1.00,1.00)	30.570 8	59.835 5
11	1.118 0	(1.00,0.50)	26.133 1	53.039 1
12	1.250 0	(0.75,0)	19.146 5	39.336 2
13	1.356 6	(1.00,0.25)	15.315 0	31.032 2
14	1.536 6	(1.50,1.00)	11.013 2	21.687 2
15	1.581 1	(1.50,1.50)	10.553 3	20.181 5
16	1.666 7	(1.00,0)	9.034 0	16.674 3
17	1.677 1	(1.50,0.75)	8.912 4	16.589 3
18	1.900 3	(1.50,0.50)	6.582 1	11.025 7
19	2.006 9	(2.00,1.50)	5.927 4	9.180 8
20	2.108 2	(2.00,2.00)	5.210 6	7.834 8
21	2.181 0	(1.50,0.25)	4.817 8	7.024 5
22	2.236 1	(2.00,1.00)	4.575 0	6.525 9
23	2.450 9	(2.00,0.75)	3.731 3	4.878 5
24	2.500 0	(1.50,0)	3.603 9	4.520 5
25	2.500 0	(2.50,2.00)	3.557 3	4.552 4
26	2.635 2	(2.50,1.50)	3.169 7	3.868 1
27	2.635 2	(2.50,2.50)	3.163 7	3.768 6
28	2.713 1	(2.00,0.50)	3.008 5	3.514 0
29	3.004 6	(2.50,1.00)	2.377 0	2.538 8
30	3.004 6	(3.00,2.50)	2.398 3	2.565 0
31	3.010 4	(2.00,0.25)	2.369 1	2.531 7
32	3.073 2	(3.00,2.00)	2.271 5	2.421 1
33	3.162 3	(3.00,3.00)	2.182 2	2.217 9
34	3.254 3	(2.50,0.75)	2.038 5	2.031 7
35	3.333 3	(2.00,0)	1.939 3	1.962 5
36	3.354 1	(3.00,1.50)	1.925 0	1.907 4
37	3.535 5	(2.50,0.50)	1.743 6	1.672 3
38	3.800 6	(3.00,1.00)	1.530 9	1.429 7
39	3.841 5	(2.50,0.25)	1.512 4	1.414 4
40	4.069 7	(3.00,0.75)	1.382 6	1.286 7

续表

Continue table

实验序号	λ	δ	超控 ARL(D 控制图)	超控 ARL(T^2 控制图)
41	4.166 7	(2.50,0)	1.335 0	1.236 5
42	4.362 1	(3.00,0.50)	1.258 0	1.174 2
43	4.673 4	(3.00,0.25)	1.159 9	1.097 0
44	5.000 0	(3.00,0)	1.097 8	1.048 4

分别选取表 1 中序号 1,2,4,5,8,11,13,14,17,18,20,23,28,29,33,35,37,39,40,42,43,44 进行实验,仿真结果如图 5 所示. 所有在控 ARL 及超控 ARL 都是通过 10 000 次实验得出的. 由于 D 控制图与 T^2 控制图的监控统计量不一样. 因此,它们所调整计算出的控制限 h 也不一样.

由表 1 与图 5 可知:相较于 T^2 控制图,提出的 D 控制图具有几乎一样,甚至更好的监控性能,特别是在中小阶跃幅度时,其具有明显更优的监控性能. 这是因为传统的 T^2 控制图是基于数理统计的方法构建的,而 D 控制图是在机器学习方法基础上构建的.

因此, D 控制图能够通过对制造过程历史数据的学习,调整自身结构,实现对当前制造过程更好的监控. 比较结果也说明 D 控制图在多变量制造过程中是一个更理想的监控模型.




图 5 不同控制图的仿真结果

Fig. 5 Simulation results of different control charts

4 应用实例

通过 D 控制图和 T^2 控制图监控一个木材加工厂的制造过程^[17],以说明 D 控制图在实际应用的优越性. 木材加工厂的制造过程是一个典型的两变量过程,木材的硬度和弯曲应力是该制造过程的 2 个质量特性. 在进行在线监控之前,首先,将采集到的在控数据的 T^2 统计值以 16 维移动窗口向量的形式输入 SVDD 进行离线训练. 然后,利用在控数据,调节控制限 h ,使在控 ARL 大约为 370. 分别用 D 控制图和 T^2 控制图监控 115 组观测数据,制造过程在第 55 组数据开始出现过程失控. 监控结果如图 6 所示. 由图 6 可知: D 控制图在第 61 组观察点的 D 值超过了控制限 h ,而 T^2 控制图在第 96 组观察点才发出警报信号.




图 6 监控木材加工过程实例

Fig. 6 Examples for monitoring lumber manufacturing

进一步对表现结果进行分析, D 控制图有更好的监控性能主要有以下 2 点原因. 1) D 控制图是在机器学习方法基础上构建的监控模型. 因此, D 控制图能够通过对制造过程历史数据的学习,调整自身结构,实现对当前制造过程更好的监控. 而 T^2 控制图是基于数理统计的方法建立的,不能对制造过程的实际情况调整自身结构. 2) D 控制图是将采集到的数据以移动窗口向量的形式输入,所以更多的异常特征可以输入监控模型中,这样的监控模型可以更容易超过它的控制限,更快地监控到异常. 而 T^2 控制图只能监控当前观测值的信息,因此,更难超过它的控制限.

5 结束语

提出基于支持向量数据描述的 D 控制图,克服传统控制图不具备自学习的特点,能够根据不同的制造过程,通过学习不断改进自身结构.因此, D 控制图具有更好的应用性.由于 SVDD 是一种无监督学习算法,所以, D 控制图的学习只需要在控数据,这样可进一步减少在数据收集方面的消耗. D 控制图具有应用性和经济性两大特点.仿真实验及应用实例证明, D 控制图在多变量制造过程中是一个理想的监控工具.

参考文献:

- [1] 张鹏伟,苏秦,李乘龙.面向小批量生产过程的多变量贝叶斯控制图[J].系统工程学报,2013,28(3):387-393. DOI:10.3969/j.issn.1000-5781.2012.01.013.
- [2] 汪洋,陈向东,闪四清.基于 ARL 的 T^2 控制图多元质量特性统计设计经济模型[J].工业工程,2013,16(4):133-139.
- [3] LIANG Wenjuan,PU Xiaolong,XIANG Dongdong. A distribution-free multivariate CUSUM control chart using dynamic control limits[J]. Journal of Applied Statistics,2017,44(11):1-19. DOI:10.1080/02664763.2016.1247784.
- [4] WOODALL W H,NCUBE M M. Multivariate CUSUM quality-control procedures[J]. Technometrics,1985,27(3):285-292. DOI:10.2307/1269710.
- [5] LOWRY C A,WOODALL W H,CHAMP C W,et al. A multivariate exponentially weighted moving average control chart[J]. Technometrics,1992,34(1):46-53. DOI:10.2307/1269551.
- [6] 张学工.关于统计学习理论与支持向量机[J].自动化学报,2000,26(1):32-42. DOI:10.16383/j.aas.2000.01.005.
- [7] TAX D M J,DUIN R P W. Support vector domain description[J]. Pattern Recognition Letters,1999,20(11):1191-1199. DOI:10.1016/S0167-8655(99)00087-2.
- [8] TAX D M J,DUIN R P W. Support vector data description[J]. Machine Learning,2004,54(1):45-66. DOI:10.1023/B:MACH.0000008084.60811.49.
- [9] BUSCEMA M. Back propagation neural networks[J]. Substance Use and Misuse,1998,33(2):233-270.
- [10] KOHONEN T. Essentials of the self-organizing map[J]. Neural Networks,2013,37(1):52-65. DOI:10.1016/j.neunet.2012.09.018.
- [11] SHI Dongfeng,GINDY N N. Tool wear predictive model based on least squares support vector machines[J]. Mechanical Systems and Signal Processing,2007,21(4):1799-1814. DOI:10.1016/j.ymssp.2006.07.016.
- [12] XI Lifeng. Using an MQE chart based on a self-organizing map NN to monitor out-of-control signals in manufacturing processes[J]. International Journal of Production Research,2008,46(21):5907-5933. DOI:10.1080/00207540701358729.
- [13] LAZZARETTI A E,TAX D M J,NETO H V,et al. Novelty detection and multi-class classification in power distribution voltage waveforms[J]. Expert Systems with Applications,2016,45(C):322-330. DOI:10.1016/j.eswa.2015.09.048.
- [14] 王佼,刘艳春.应用灰关联分析的 PSO-SVR 工程造价预测模型[J].华侨大学学报(自然科学版),2016,37(6):708-713. DOI:10.11830/ISSN.1000-5013.201606010.
- [15] 邹心遥,陈敬伟,姚若河.采用粒子群优化的 SVM 算法在数据分类中的应用[J].华侨大学学报(自然科学版),2016,37(2):171-174. DOI:10.11830/ISSN.1000-5013.2016.02.0171.
- [16] GARCÍA-ESCUADERO L A,DUQUE-PEREZ O,FERNANDEZ-TEMPRANO M,et al. Robust detection of incipient faults in VSI-fed induction motors using quality control charts[J]. IEEE Transactions on Industry Applications,2017,53(3):3076-3085. DOI:10.1109/TIA.2016.2617300.
- [17] MOVAFFAGH A,AMIRI A. Monotonic change point estimation in the mean vector of a multivariate normal process[J]. International Journal of Advanced Manufacturing Technology,2013,69(5/6/7/8):1895-1906.

(责任编辑:钱筠 英文审校:吴逢铁)