

DOI: 10.19650/j.cnki.cjsi.J2006827

基于变量分块的 KDLV-DWSVDD 间歇过程 故障检测算法研究*

赵小强^{1,2,3}, 牟 森¹

(1. 兰州理工大学电气工程与信息工程学院 兰州 730050; 2. 甘肃省工业过程先进控制重点实验室,
兰州 730050; 3. 兰州理工大学国家级电气与控制工程实验教学中心 兰州 730050)

摘 要:非线性动态间歇过程中,测量变量存在不同的序列相关性,且变量间的交叉相关性会体现在不同的采样时刻上,然而传统检测方法没有考虑这种变量间的相关性,通常将所有变量视为独立或相关关系进行特征提取,不能充分提取到故障信息的特征,造成监测效果不佳。因此,提出一种基于变量分块的核动态潜变量-动态加权支持向量数据描述(KDLV-DWSVDD)间歇过程故障检测算法。首先,通过求取变量间的互信息值(MI)将变量分为相关与独立两个变量子块;然后,通过 KDLV 算法将相关变量子块分为动态部分和静态部分,对动态部分建立向量自回归模型进行监测,对静态部分采用邻域保持嵌入(NPE)算法进行监测;独立变量子块中自变量的动态信息可通过 DWSVDD 算法进行提取;最后,通过 KDLV-DWSVDD 算法建立监控统计量进行故障检测。所提算法在青霉素发酵仿真过程中平均故障检测率可达 90.38%,相较于对比算法提高了近 15%,半导体实际工业过程也证明了所提算法对于间歇过程故障检测的可行性和优越性。

关键词: 间歇过程;故障检测;互信息;动态潜变量;支持向量数据描述;邻域保持嵌入

中图分类号: TP277 TH165.3 **文献标识码:** A **国家标准学科分类代码:** 510.80

Research on fault detection algorithm of batch process based on KDLV-DWSVDD of variable blocks

Zhao Xiaoqiang^{1,2,3}, Mou Miao¹

(1. College of Electrical and Information Engineering, Lanzhou University of Technology, Lanzhou 730050, China;

2. Gansu Key Laboratory of Advanced Control for Industrial Processes, Lanzhou 730050, China;

3. National Experimental Teaching Center of Electrical and Control Engineering,
Lanzhou University of Technology, Lanzhou 730050, China)

Abstract: In non-linear dynamic batch processes, the measured variables have different serial correlations, and the cross correlation among the variables could be reflected at different sampling moments, however, traditional detection methods do not consider the correlation among the variables, the relationships among all variables are usually regarded as independent or correlative for feature extraction, and the features of fault information are not fully extracted, so the monitoring effect is bad. Therefore, a batch process fault detection algorithm based on the kernel dynamic latent variable-dynamically weighted support vector data description (KDLV-DWSVDD) of variable blocks is proposed. Firstly, the variables are divided into related and independent variable sub-blocks through obtaining mutual information (MI) values among the variables. Then, KDLV algorithm is used to divide the related variable sub-block into a dynamic part and a static part, the vector auto-regressive model is established to monitor the dynamic part and the neighborhood preserving embedding (NPE) algorithm is used to monitor the static part. In the independent variable sub-block, DWSVDD algorithm can be used to extract the dynamic information of independent variables. Finally, the monitoring statistics are established for fault detection through KDLV-DWSVDD algorithm. The average fault detection rate of the proposed algorithm in the penicillin fermentation simulation process reaches 90.38%, which is nearly improved by 15% compared with that of the comparison algorithms. The actual

收稿日期:2020-08-27 Received Date: 2020-08-27

* 基金项目:国家自然科学基金(61763029)、甘肃省工业过程先进控制重点实验室开放基金(2019KFJJ01)项目资助

semiconductor industry process also proves the feasibility and superiority of the proposed algorithm for the fault detection of batch processes.

Keywords: batch process; fault detection; mutual information; dynamic latent variable; support vector data description; neighborhood preserving embedding

0 引 言

随着现代工业过程规模的扩大,确保工业生产过程的安全可靠尤为重要。间歇生产过程作为工业过程中一种重要的生产方式,因其生产过程数据呈现强非线性、动态性、时变、多模态等特性,以及生产设备导致的数据缺失、不规则采样及粗大误差等导致的监控效果不佳的问题,使得间歇过程故障检测受到越来越多学者的关注。近年来,以 PCA、ICA 等为代表的基于数据驱动故障检测方法因其能够有效提取过程信息,已作为保障生产过程安全的重要方法得到了广泛应用^[1-3]。

传统 PCA 等数据驱动方法在进行故障检测时都要求测量变量序列不相关,但随着计算机和 DCS 技术在现代工业过程中的广泛应用,采样数据之间不可避免的存在序列相关性,即存在动态特性。针对动态过程故障检测, Ku 等^[4]利用包含当前和过去时刻采样值的增广矩阵进行建模,提出了动态主元分析(dynamic principal component analysis, DPCA)方法;为了有效提取数据的动态信息和局部信息,苗爱敏等^[5]提出了一种基于时序扩展的邻域保持嵌入(neighborhood preserving embedding based on temporal extension, TNPE)算法,在邻域保持嵌入算法保持数据局部结构的基础上引入了时序扩展,从而体现数据之间的动态关系。但是上述方法都没有对过程变量的动态关系和静态关系进行区分,为了解决无法有效地提取动态特征的问题, Li 等^[6]提出了一种基于动态潜变量(dynamic latent variable dynamic, DLV)的动态过程检测方法,该方法能够区分过程数据的自相关性和交叉相关性,同时,由于分别提取了动态成分和静态成分,提取后数据可以很好地解释数据的动态潜隐成分。之后又有众多学者提出了很多的 DLV 改进算法^[7-9]。然而,现代工业过程中不同测量变量存在不同的自相关性且变量间的相互影响会体现在不同的采样时刻上,同时, DLV 方法本质上仍是一种线性方法,对于非线性过程无法很好地处理,采用 DLV 方法对非线性动态过程进行故障检测还需要进一步研究。

支持向量数据描述(support vector data description, SVDD)是一种单类分类器,可用于样本分类和异常点检测,具有较好的非线性处理能力^[10-13]。祝志博等^[14]提出了一种基于 PCA-SVDD 的故障检测方法,采用 PCA 方法进行降维后利用 SVDD 方法建立监测模型实现在线监

测;王晶等^[15]提出了一种基于 SVDD 的多时段间歇过程故障检测方法,通过对不同时段分别建立 SVDD 模型实现故障检测。但上述方法在建模过程中均忽略了变量的相关性和变量间的交叉相关性,一定程度上也影响了检测效果。

在信息论中,互信息(mutual information, MI)通常指一个随机变量中包含的另一个随机变量的信息量^[16],是一种非线性、无参数的度量指标,相较于相关系数等方法,互信息在描述变量线性关系的同时也能够评估变量间的非线性关系。目前,互信息已经较为广泛的应用在多变量统计过程中^[17-20]。

因此针对不同测量变量存在不同的自相关性且变量间的交叉相关性影响故障检测效果的问题,本文提出了一种基于变量分块的核动态潜变量—动态加权支持向量数据描述(kernel dynamic latent variable dynamically weighted support vector data description, KDLV-DWSVDD)的间歇过程故障检测算法。首先,对每个变量计算与其它变量间的互信息值,将过程变量划分为相关变量和独立变量两个子块;然后,在相关变量中, KDLV 算法分别提取动态信息和静态信息,在动态部分建立向量自回归(vector auto-regressive, VAR)模型进行监测,在静态部分采用邻域保持嵌入(neighborhood preserving embedding, NPE)算法进行监测, KDLV 方法能够去除特有变化部分过程噪声并有效提取整个采样数据的动态潜变量,有效提取非线性动态信息;在独立变量子块中, DWSVDD 算法能够有效抑制噪声并提取动态信息;最后,基于变量分块的 KDLV-DWSVDD 间歇过程故障检测算法将在青霉素发酵过程仿真平台和半导体工业过程通过对比分析进行验证。

1 基础算法

1.1 DLV 算法

假设样本矩阵定义为 $X = [x_1 x_2 \dots x_n]$, $X_i = [x_{i+1} x_{i+2} \dots x_{i+n-q+1}]$, ($i = 0, \dots, q-1$), $Z = [x_0, \dots, x_{q-1}]$ 是特征空间中 $n \times (q \times m)$ 的增广矩阵,为了提取数据矩阵 X 中序列自相关的动态潜变量特征, DLV 算法定义的目标函数为:

$$\begin{aligned} \max_{\omega, \beta} & (\beta \otimes \omega)^T Z^T Z (\beta \otimes \omega) \\ \text{s. t.} & \omega^T \omega = 1, \beta^T \beta = 1 \end{aligned} \quad (1)$$

其中, $(\beta \otimes \omega) = [\beta_0 \omega^T, \beta_1 \omega^T, \dots, \beta_{q-1} \omega^T]^T$ 是克罗

内积,式(1)旨在搜寻系数向量 $\boldsymbol{\beta} = [\beta_0, \beta_1, \dots, \beta_{q-1}]^T$ 与投影变换向量 $\boldsymbol{\omega} \in R^{m \times 1}$, 由 $\boldsymbol{t}_k = \boldsymbol{x}_k^T \boldsymbol{\omega}$ 得到自相关的动态潜变量。DLV 模型如式(2)所示。

$$\begin{cases} \boldsymbol{t}_k = \boldsymbol{A}_1 \boldsymbol{t}_{k-1} + \dots + \boldsymbol{A}_p \boldsymbol{t}_{k-p} + \boldsymbol{v}_k \\ \boldsymbol{x}_k = \boldsymbol{P} \boldsymbol{t}_k + \boldsymbol{e}_k \end{cases} \quad (2)$$

其中, \boldsymbol{A}_p 是阶次为 p 的自回归过程的参数矩阵; \boldsymbol{v}_k 表示一个随机过程; \boldsymbol{P} 是特征空间的加载矩阵; \boldsymbol{e}_k 是特征空间的模型误差。

1.2 SVDD 算法

针对样本矩阵 $\boldsymbol{X} = [\boldsymbol{x}_1, \boldsymbol{x}_2, \dots, \boldsymbol{x}_n]$, SVDD 算法的基本思想通过非线性映射将 \boldsymbol{X} 映射到高维特征空间, 找到一个几乎包含所有样本的最优超球体, 判断一个新的样本点在特征空间中是否落入超球体内, 则可判断该样本点是否异常。此问题可描述为:

$$\begin{aligned} & \min_{R, \boldsymbol{\varepsilon}, \xi_i} (R^2 + C \sum_i \xi_i) \\ & \text{s. t. } \|\Phi(\boldsymbol{x}_i) - \boldsymbol{\varepsilon}\|^2 \leq R^2 + \xi_i, \xi_i \leq 0, i = 1, 2, \dots, n \end{aligned} \quad (3)$$

其中, $\boldsymbol{\varepsilon}$ 和 R 分别表示超球体的球心和半径; ξ_i 为松弛因子; C 为惩罚参数; 它表示样本被错误分类的概率。式(4)为式(3)的对偶形式, 可通过求解式(4)的对偶问题求解式(3)的最优化问题:

$$\begin{aligned} & \min_{\alpha_i} \sum_{i=1}^n \alpha_i \langle \Phi(\boldsymbol{x}_i) \cdot \Phi(\boldsymbol{x}_i) \rangle - \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j \langle \Phi(\boldsymbol{x}_i) \cdot \Phi(\boldsymbol{x}_j) \rangle \\ & \text{s. t. } \sum_i \alpha_i = 1, 0 \leq \alpha_i \leq C \end{aligned} \quad (4)$$

其中, α_i 是拉格朗日因子。

引入核函数 $K(\boldsymbol{x}_i \cdot \boldsymbol{x}_j)$ 代替内积 $\langle \Phi(\boldsymbol{x}_i) \cdot \Phi(\boldsymbol{x}_j) \rangle$ 将非线性问题映射到高维的线性问题, 可得式(5):

$$\begin{aligned} & \max L = \sum_{i=1}^n \alpha_i K(\boldsymbol{x}_i \cdot \boldsymbol{x}_i) - \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j K(\boldsymbol{x}_i \cdot \boldsymbol{x}_j) \\ & \text{s. t. } \sum_i \alpha_i = 1, 0 \leq \alpha_i \leq C \end{aligned} \quad (5)$$

通过求解式(4)、(5)的优化问题得出超球体的球心 $\boldsymbol{\varepsilon}$ 以及半径 R , 若 \boldsymbol{x}_k 是 SVDD 模型的支持向量, 则:

$$\boldsymbol{\varepsilon} = \sum_{i=1}^n \alpha_i \boldsymbol{\varphi}(\boldsymbol{x}_i) \quad (6)$$

$$R^2 = 1 - 2 \sum_{i=1}^n \alpha_i K(\boldsymbol{x}_i \cdot \boldsymbol{x}_i) + \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j K(\boldsymbol{x}_i \cdot \boldsymbol{x}_j) \quad (7)$$

利用式(8)可计算新的样本 $\boldsymbol{x}_{\text{new}}$ 到超球体球心的距离:

$$\begin{aligned} & R_{\text{new}}^2 = \|\Phi(\boldsymbol{x}_{\text{new}}) - \boldsymbol{\varepsilon}\|^2 = 1 - 2 \sum_{i=1}^n \alpha_i K(\boldsymbol{x}_{\text{new}} \cdot \boldsymbol{x}_i) + \\ & \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j K(\boldsymbol{x}_i \cdot \boldsymbol{x}_j) \leq R^2 \end{aligned} \quad (8)$$

如果 $R_{\text{new}}^2 \leq R^2$ 则该样本正常, 反之, 该样本为异常

样本。

1.3 MI

变量 x 的熵 $H(x)$ 如式(9)所示。

$$H(x) = - \int_x p(x) \log p(x) dx \quad (9)$$

其中, $p(x)$ 表示变量 x 的概率密度值。则可通过式(10)求解 x_1 和 x_2 的互信息值:

$$I(x_1, x_2) = \int_{x_1} \int_{x_2} p(x_1, x_2) \log \frac{p(x_1, x_2)}{p(x_1)p(x_2)} dx_1 dx_2 \quad (10)$$

其中, $p(x_1, x_2)$ 为 x_1 和 x_2 的联合概率密度。式(10)可以写成基于熵的形式, 如式(11)所示。

$$I(x_1, x_2) = H(x_1) + H(x_2) - H(x_1, x_2) \quad (11)$$

其中, $H(x_1)$ 和 $H(x_2)$ 分别是 x_1 和 x_2 的熵, $H(x_1, x_2)$ 是 x_1 和 x_2 的联合熵, 可以通过式(12)得到。

$$H(x_1, x_2) = - \int_{x_1} \int_{x_2} p(x_1, x_2) \log p(x_1, x_2) dx_1 dx_2 \quad (12)$$

2 基于变量分块的 KDLV-DWSVDD 算法的间歇过程故障检测

2.1 变量分块

非线性动态间歇过程中变量间的关系是复杂的, 传统方法单一的假设变量之间是相关的或独立的, 但实际上变量之间存在线性相关、非线性相关、弱相关或相互独立等关系, 为了达到更好的检测效果, 应将相关变量和独立变量分离出来分别进行监控。

对于变量矩阵 $\boldsymbol{X} = [\boldsymbol{x}_1, \boldsymbol{x}_2, \dots, \boldsymbol{x}_m] \in R^{n \times m}$, 可以通过求解变量间的互信息值得到相关或独立关系, 作为度量变量间相关性的方法, 当两个变量的互信息越大, 则说明两个变量的相关性越大, 若互信息值接近于 0 时, 则两变量独立。

对变量 $\boldsymbol{x}_i (i = 1, 2, \dots, m)$ 建立互信息向量, 其中向量的元素为 \boldsymbol{x}_i 与其它 $m - 1$ 个变量的互信息值。构造一个随机矩阵 $\boldsymbol{R}' = [\boldsymbol{r}'_1, \boldsymbol{r}'_2, \dots, \boldsymbol{r}'_{m-1}] \in R^{n \times m-1}$, 其中 $\boldsymbol{r}'_i (i = 1, 2, \dots, m - 1)$ 是一个零均值单位方差的高斯分布, 在变量 \boldsymbol{x}_i 与随机矩阵 \boldsymbol{R}' 中 $m - 1$ 个变量间计算互信息值构成向量 $\boldsymbol{q}_i \in R^{m-1}$, \boldsymbol{R}' 中的任意两个变量都不相关, 且 \boldsymbol{R}' 中的任意变量 \boldsymbol{r}'_i 独立于原始矩阵中的任意变量 \boldsymbol{x}_i 。若 \boldsymbol{x}_i 与其他变量对应的互信息值所构成的向量 \boldsymbol{p}_i 将接近于零向量, 则它们相互独立; 反之则相互相关, \boldsymbol{p}_i 值较大。 \boldsymbol{p}_i 的范数可由 $D_i = \|\boldsymbol{p}_i\|_2$ 计算得出, 若 D_i 较小, 则表示 \boldsymbol{x}_i 与其他变量相互独立, 建立一个控制限 cN_i 将原始变量划分为独立变量子块与相关变量子块, 其中 $N_i = \|\boldsymbol{q}_i\|_2$, c 为随机因子, 若 D_i 超过控制限 cN_i 时, 则认为 \boldsymbol{x}_i 其他变量是相关的, 若 D_i 在控制限 cN_i 之内时, 则认为 \boldsymbol{x}_i 其他变量是独立的。

通过上述方法将变量集 \mathbf{X} 划分为相关变量子块 \mathbf{X}_R 和独立变量子块 \mathbf{X}_I 两部分,如式(13)所示。

$$\mathbf{X} = [\mathbf{X}_R, \mathbf{X}_I] \quad (13)$$

2.2 变量分块的KDLV-DWSVDD算法建模

DLV方法仅考虑了数据的线性特性,并没有考虑数据中存在的非线性的互相关和自相关,从而影响监测效果,针对该问题,本文利用互信息将变量分为相关变量子块和独立变量子块,在相关变量子块中用KDLV算法提取动态潜变量和静态信息,在独立变量子块中,增加前 h 个时刻的观测数据得到增广矩阵建立DWSVDD统计模型从而提取其动态信息。

为了对非线性过程进行监测,引入核函数对DLV算法进行扩展,设 $\Phi(\cdot)$ 表示映射函数, $\Phi(\mathbf{X})$ 表示矩阵中每个样本 \mathbf{x}_i 用 $\Phi(\mathbf{x}_i)$ 替换,则KDLV定义的目标函数与模型如式(14)和(15)所示。

$$\begin{aligned} & \max_{\omega, \beta} (\beta \otimes \omega)^T \mathbf{Z}_\Phi^T \mathbf{Z}_\Phi (\beta \otimes \omega) \\ & \text{s. t. } \omega^T \omega = 1, \beta^T \beta = 1 \end{aligned} \quad (14)$$

$$\begin{cases} \mathbf{t}_k = \mathbf{A}_1 \mathbf{t}_{k-1} + \dots + \mathbf{A}_p \mathbf{t}_{k-p} + \mathbf{v}_k \\ \Phi(\mathbf{x}_k) = \mathbf{P} \mathbf{t}_k + \mathbf{e}_k \end{cases} \quad (15)$$

其中, $\mathbf{Z}_\Phi = [\Phi(\mathbf{x}_0), \dots, \Phi(\mathbf{x}_{q-1})]$ 。

在给定一个固定 β 的情况下,求解式(14)实现 ω 的最优解:

$$\omega_{opt} = 1/\lambda_\beta \mathbf{R}_\beta \omega_{opt} = \sum_{i=1}^n \Phi(\mathbf{x}_i) \alpha_i \quad (16)$$

其中, $\mathbf{R}_\beta = (\beta \otimes \mathbf{I}_m)^T \mathbf{Z}_\Phi^T \mathbf{Z}_\Phi (\beta \otimes \mathbf{I}_m)$ 。将式(16)代入式(14)得到:

$$\mathbf{J} = (\beta \otimes \alpha^T)^T \Phi(\mathbf{X}) \mathbf{Z}_\Phi^T \mathbf{Z}_\Phi \Phi(\mathbf{X}) (\beta \otimes \alpha) \quad (17)$$

本文选择应用较普遍的径向基函数 $k(\mathbf{x}, \mathbf{y}) = \Phi(\mathbf{x})^T \cdot \Phi(\mathbf{y}) = \exp\left(-\frac{|\mathbf{x} - \mathbf{y}|^2}{\sigma^2}\right)$, 参数 σ 为核窗宽。定义 $\mathbf{K} = \Phi(\mathbf{X}) \Phi(\mathbf{X})^T$, $\mathbf{K}_i = \Phi(\mathbf{X}) \Phi(\mathbf{X}_i)^T$ 。式(17)在 α 和 β 的限制下可写为:

$$\begin{aligned} & \max_{\alpha, \beta} \mathbf{J} = (\beta \otimes \alpha)^T \mathbf{K}_z \mathbf{K}_z (\beta \otimes \alpha) \\ & \text{s. t. } \alpha^T \mathbf{K} \alpha = 1, \beta^T \beta = 1 \end{aligned} \quad (18)$$

其中, $\mathbf{K}_z = [\mathbf{K}_0^T, \mathbf{K}_1^T, \dots, \mathbf{K}_{q-1}^T]$ 。

定义以下矩阵:

$$\begin{aligned} \mathbf{S}_z &= \mathbf{K}_z^T \mathbf{K}_z \in \mathbf{R}^{nq \times nq} \\ \mathbf{S}_\alpha &= (\mathbf{I}_q \otimes \alpha)^T \mathbf{S}_z (\mathbf{I}_q \otimes \alpha) \in \mathbf{R}^{q \times q} \\ \mathbf{S}_\beta &= (\beta \otimes \mathbf{I}_n)^T \mathbf{S}_z (\beta \otimes \mathbf{I}_n) \in \mathbf{R}^{n \times n} \end{aligned} \quad (19)$$

则式(18)的最优解可通过迭代求解式(20)的特征向量得到:

$$\begin{aligned} \mathbf{S}_\alpha \beta &= \lambda_\beta \beta \\ \mathbf{S}'_\beta \alpha' &= \lambda_\alpha \alpha' \end{aligned} \quad (20)$$

其中, $\mathbf{S}'_\beta = \mathbf{K}^{-\frac{1}{2}} \mathbf{S}_\beta \mathbf{K}^{-\frac{1}{2}}$, $\alpha' = \mathbf{K}^{-\frac{1}{2}} \alpha$, 满足 $\alpha'^T \alpha' = 1$ 。

式(20)很难求出最优解,故给出一个迭代算法来求解该优化问题,具体步骤如下:

1) KDLV搜索算法

(1) 以零均值和小方差随机初始化 $\alpha \in \mathbf{R}^n$;

(2) 根据式(19)计算 $\mathbf{S}_\alpha, \beta = \mathbf{S}_\alpha \beta / \|\mathbf{S}_\alpha \beta\|$;

(3) 根据式(19)计算 $\mathbf{S}'_\beta, \alpha' = \mathbf{S}'_\beta \alpha' / \|\mathbf{S}'_\beta \alpha'\|$;

(4) 计算 $\alpha = \mathbf{K}^{-\frac{1}{2}} \alpha'$;

(5) 如果 α' 收敛于一个较小的区域,则停止;否则,转向步骤(2)。定义收敛误差: $\varepsilon(k) = (I - \alpha'(k-1)\alpha'^T(k-1)\alpha'(k))$ 。

获得系数 α 后,可以由算法1)提取动态潜变量和静态潜变量。

2) KDLV建模算法

(1) 将原始变量标准化为零均值和单位方差,初始化 $i = 1, \mathbf{K}^i = \mathbf{K}$;

(2) 根据算法1)用 \mathbf{K}^i 搜索 α_i ;

(3) 计算动态得分 $\mathbf{t}_i = \mathbf{K}^i \alpha_i$;

(4) 计算投影矩阵 $\pi_i = I - \mathbf{t}_i \mathbf{t}_i^T / \mathbf{t}_i^T \mathbf{t}_i$;

(5) 更新核矩阵 $\mathbf{K}^{i+1} = \pi_i \mathbf{K}^i \pi_i$; 令 $i = i + 1$, 若 $i > A$, 则停止;否则,返回步骤(2);

(6) 对 \mathbf{K}^A 进行SVD得 $\mathbf{K}^A = \mathbf{U} \mathbf{D} \mathbf{V}^T$ 。 $\alpha_s = U[:, 1:A_s]$ 是静态潜变量系数。其中, A 是保留的动态潜变量的数量, A_s 是保留的静态潜变量的数量。 $\alpha = [\alpha_1 \dots \alpha_A]$, $\mathbf{T} = [\mathbf{t}_1 \dots \mathbf{t}_A]$ 。动态潜变量可从核矩阵 \mathbf{K} 中提取:

$$\mathbf{T} = \mathbf{K} \mathbf{R} \quad (21)$$

其中, $\mathbf{R} = \alpha (\mathbf{T}^T \mathbf{K} \alpha)^{-1} (\mathbf{T}^T \mathbf{T})$ 由系数 α 计算得到。

给定一个样本 \mathbf{x}_k , 其动态和静态潜变量可由式(22)求得。

$$\begin{cases} \mathbf{t}_k = \mathbf{R}^T \mathbf{k}_k \\ \mathbf{t}_{s,k} = \alpha_s^T \mathbf{\Pi} (\mathbf{k}_k - \mathbf{K} \mathbf{T}_A \mathbf{t}_k) \end{cases} \quad (22)$$

其中, $\mathbf{\Pi} = (I - \mathbf{T} (\mathbf{T}^T \mathbf{T})^{-1} \mathbf{T}^T)$ 是投影矩阵, $\mathbf{T}_A = \mathbf{T} (\mathbf{T}^T \mathbf{T})^{-1}$ 是归一化的 \mathbf{T} 。

对提取完动态信息的动态潜变量建立向量自回归模型:

$$\mathbf{t}_k = \sum_{j=1}^p \theta_j \mathbf{t}_{k-j} + \mathbf{v}_k = \Theta [\mathbf{t}_{k-1}^T, \dots, \mathbf{t}_{k-p}^T]^T + \mathbf{v}_k \quad (23)$$

式中: p 表示模型阶数; θ_j 为 $l_d \times l_d$ 阶方阵。若令 $\Theta = [\theta_1^T, \dots, \theta_p^T]^T$, Θ 每一行可由最小二乘法得到其无偏估计。

由于动态主元数据具有很强的时序相关性,故选择噪声 \mathbf{v} 作为监测量,其统计量和控制限分别为:

$$\begin{aligned} \mathbf{T}_d^2 &= \mathbf{v}^T \left(\frac{1}{n} \mathbf{V}^T \mathbf{V} \right) \mathbf{v} \\ \mathbf{T}_{da}^2 &= \frac{A_d (N^2 - 1)}{N (N - A_d)} F_{A_d, N - A_d, \alpha} \end{aligned} \quad (24)$$

矩阵 \mathbf{X} 在提取完动态潜变量后剩余的信息之间存在交叉相关性,可进一步使用 *NPE* 方法^[21-22]建模提取静态局部信息,*NPE* 先为每个数据点寻找其 k 近邻并为其赋权值,定义重构误差为:

$$\Phi(\mathbf{W}) = \sum_{i=1}^n \left\| \mathbf{x}_i - \sum_{j=1}^n W_{ij} \mathbf{x}_j \right\|^2 \quad (25)$$

NPE 算法的思想是若在高维空间中 W_{ij} 可以重构数据点 \mathbf{x}_i ,则在低维空间中可通过相同的权值来重构对应数据点 \mathbf{y}_i ,特征映射可通过最小化式(26)求解。

$$\Phi(\mathbf{A}) = \sum_i \left\| \mathbf{y}_i - \sum_j W_{ij} \mathbf{y}_j \right\|^2 \quad (26)$$

其中, $\mathbf{M} = (\mathbf{I} - \mathbf{W})^T (\mathbf{I} - \mathbf{W})$,约束为: $\mathbf{y}^T \mathbf{y} = \mathbf{a}^T \mathbf{X} \mathbf{X}^T \mathbf{a} = \mathbf{I}$ 。投影矩阵 \mathbf{A} 的列向量可以通过求解式(27)的广义特征值得到:

$$\mathbf{X} \mathbf{M} \mathbf{X}^T \mathbf{a} = \lambda \mathbf{X} \mathbf{X}^T \mathbf{a} \quad (27)$$

求解获得最小的 d 个特征值所对应的特征向量组成的投影矩阵 \mathbf{A} 。

NPE 算法统计量分别为:

$$T_s^2 = \mathbf{t}_s^T \Lambda^{-1} \mathbf{t}_s \quad (28)$$

$$SPE = \left\| \mathbf{E} - \hat{\mathbf{E}} \right\|^2 = \left\| (\mathbf{I} - \mathbf{P}_s \mathbf{P}_s^T) \mathbf{e} \right\|^2$$

对应的控制限分别为:

$$T_{sa}^2 = \frac{A_s(N^2 - 1)}{N(N - A_s)} F_{A_s, N - A_s, \alpha} \quad (29)$$

$$SPE_{\alpha} = g_{h, \alpha}^2$$

2.3 DWSVDD 在独立变量子块中的建模

生产过程中,独立变量仍然具有动态特性,因此在独立空间 $\mathbf{X}_l = [\mathbf{x}_1^T \ \mathbf{x}_2^T \ \cdots \ \mathbf{x}_n^T]^T$ 中,增加前 h 个时刻的观测数据得到增广矩阵:

$$\mathbf{X}_l(h) = \begin{bmatrix} \mathbf{x}_1^T & \cdots & \mathbf{x}_{t-h}^T \\ \vdots & \ddots & \vdots \\ \mathbf{x}_{t+h-n}^T & \cdots & \mathbf{x}_{t-n}^T \end{bmatrix} \quad (30)$$

将式(30)作如下处理。

$$\mathbf{X}_l(h) = \begin{bmatrix} \tilde{\mathbf{x}}_t^T \\ \tilde{\mathbf{x}}_{t-1}^T \\ \vdots \\ \tilde{\mathbf{x}}_{t+h-n}^T \end{bmatrix} \quad (31)$$

其中, $\tilde{\mathbf{x}}_t^T = \mathbf{x}_t^T + \mathbf{x}_{t-1}^T + \cdots + \mathbf{x}_{t-h}^T$ 。

为了增强有用信息并抑制噪声,本文设计出一个权值矩阵 \mathbf{W}_r ,具体如式(32)所示。

$$\mathbf{W}_r = \frac{\text{std}(\mathbf{X}_l(h)_r)}{\sum_m \text{std}(\mathbf{X}_l(h)_m)}, r = 1, 2, \cdots, m, \sum_{r=1}^m \mathbf{W}_r = \mathbf{1} \quad (32)$$

则加权后的矩阵变为:

$$\mathbf{X}_l(h)_w = \mathbf{X}_l(h) \mathbf{W}_r \quad (33)$$

其中, \mathbf{W}_r 是一个对角矩阵, $\text{std}(\mathbf{X}_l(h)_r)$ 表示第 r 个变量的标准差。当某个变量含有较多的过程信息时,权值矩阵对这个变量赋予较大的权值从而突出有用信息,若含信息较少时,则赋予一个较小的权值抑制噪声。经过上述处理后的矩阵利用 *SVDD* 算法可以有效提取独立变量的动态特征并抑制噪声干扰,突出重要信息。

3 基于变量分块的 KDLV-DWSVDD 间歇过程故障检测

基于变量分块的 KDLV-DWSVDD 算法建模流程图如图1所示。

3.1 离线建模

1) 生成多批正常工况数据得到三维矩阵 $\mathbf{X}(I \times J \times K)$,其中 I, J, K 分别表示批次数、变量数及采样点数,首先将 \mathbf{X} 按批次方向展开并标准化后得到 $\mathbf{X}(I \times JK)$,再将其按变量方向展开为 $\mathbf{X}(IK \times J)$;

2) 使用2.1节描述的方法用 *MI* 将预处理后的数据分为独立变量子块和相关变量子块;

3) 在相关变量子块中,利用式(22)提取动态成分和静态成分;

4) 在动态成分中利用式(23)建立向量自回归模型来对动态部分进行监测,在静态成分中利用 *NPE* 算法对静态部分进行监测,并根据统计量分别求取动态部分和静态部分的控制限;

5) 在独立变量子空间中,利用式(30)对数据进行时序扩展,由式(32)求取加权矩阵,得到加权后的样本式(33);

6) 使用 *SVDD* 算法对进行时序加权处理过后的独立变量子块建立统计模型,根据统计量求取独立变量子块的控制限。

3.2 在线检测

1) 获取在线样本 $\mathbf{X}_{new}(1 \times J \times K)$,对其进行标准化处理后得到矩阵 $\mathbf{X}_{new}(K \times J)$;

2) 按照离线建模阶段步骤2)的划分结果将标准化后的在线样本 $\mathbf{X}_{new}(K \times J)$ 划分到独立变量子块和相关变量子块中得到 \mathbf{X}_l 和 \mathbf{X}_r ;

3) 对划分的相关变量子块通过离线建模阶段步骤3)和步骤4)求取相关变量的 *KDLV* 统计模型进行监测,计算统计量 T_s^2 、 T_d^2 和 *SPE*;

4) 对划分的独立变量子块通过离线建模阶段步骤5)和步骤6)求取独立变量的 *DWSVDD* 统计模型进行监测,计算统计量 R^2 ;

5) 判断统计量是否超限,若统计量超出控制限,则说明发生故障,否则返回步骤1)。

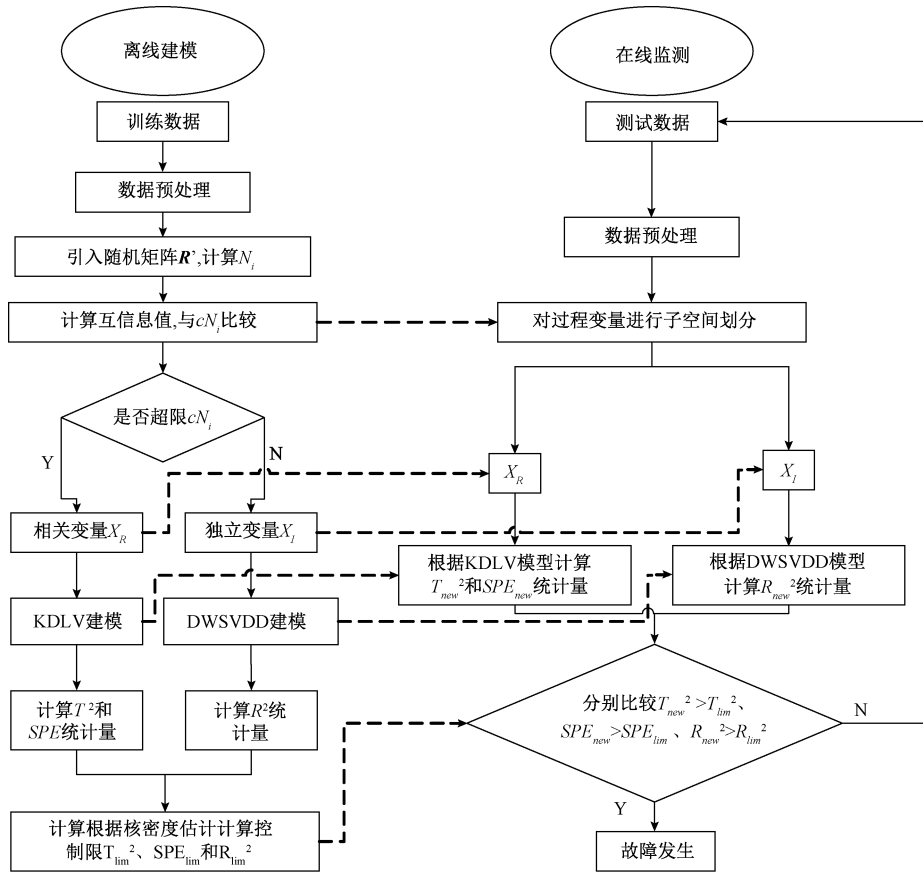


图 1 变量分块的 KDLV-DWSVDD 建模流程

Fig. 1 KDLV-DWSVDD modeling flow for variable blocks

4 青霉素发酵过程仿真验证

青霉素的生产制备过程是典型的具有非线性、动态性的间歇生产过程,本文采用美国伊利诺伊州立理工学院开发的 Pensim2.0 青霉素发酵过程标准仿真平台得到的过程数据进行仿真验证,该平台可以通过设定不同但都在正常范围内的初始条件模拟青霉素发酵过程中各变量每个时刻的数据用于分析研究,设定生成反应时间为 400 h,采样时间为 1 h,生产 30 个批次正常工况数据,并从 18 个变量中选择 10 个变量如表 1 所示作为监控变量得到三维矩阵 $X(30 \times 10 \times 400)$ 作为训练样本,需要说明的是对测量变量均加入了高斯白噪声,从而达到模拟实际生产过程中变量扰动的效果。核窗宽 σ 控制函数的径向作用范围,本文通过交叉验证方法设置 $\sigma = 5\ 000$ 。图 2 为正常批次下从 10 种监控变量中选取的 4 种监控变量的运行轨迹,从图 2 中可以看出变量间存在明显的非线性关系,也说明核函数的引入是必要的。故障种类和故障参数设置如表 2 所示。

表 1 监控变量

Table 1 Monitoring variables

变量序号	过程变量	变量序号	过程变量
1	通风速率	6	溶解氧浓度
2	搅拌功率	7	反应器体积
3	基质馈送率	8	二氧化碳浓度
4	补料温度	9	pH 值
5	基质浓度	10	发酵罐温度

表 2 不同参数下的故障类型

Table 2 Fault type under different parameters

故障序号	变量序号	故障类型	幅值/%	引入时间/h
1	1	阶跃	15	100~300
2	2	阶跃	15	100~300
3	1	斜坡	-5	100~300
4	2	斜坡	-5	100~300
5	3	斜坡	5	100~300
6	1	斜坡	5	100~300
7	2	阶跃	-2	100~300
8	3	阶跃	20	100~300

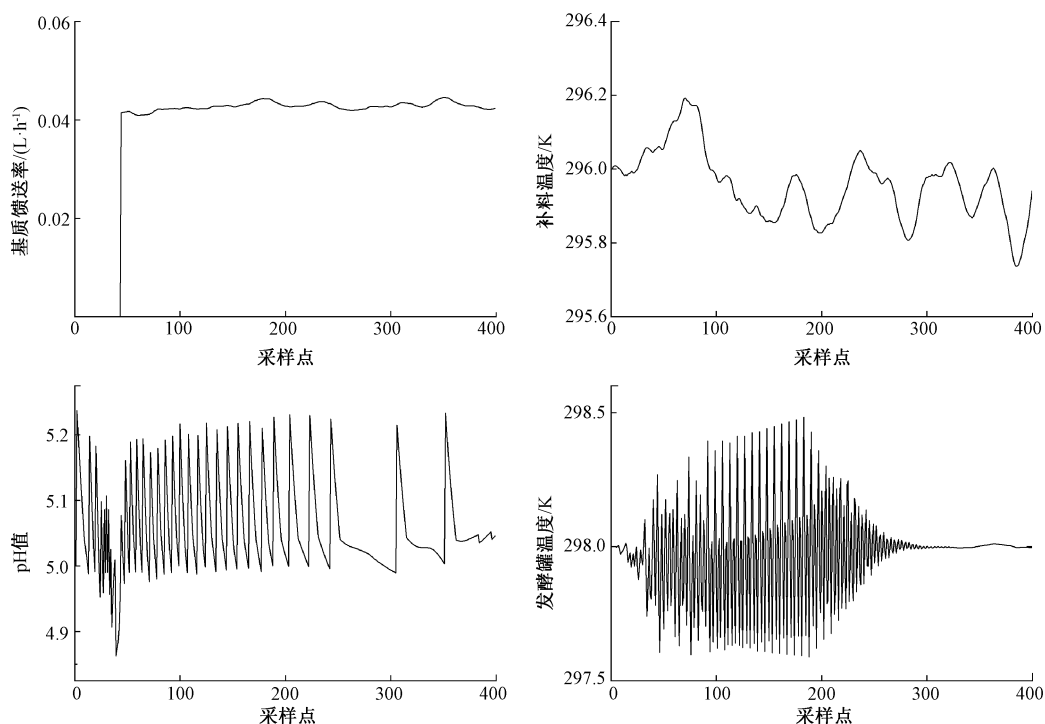


图2 正常批次下4种监控变量的轨迹

Fig. 2 The trajectories of four monitoring variables under normal batch

按照2.1节描述的变量划分方法对所选的10个过程变量进行独立变量子块与相关变量子块的划分。互信息值 D_i 如图3所示,柱高越高则表示该变量与其它变量的相关程度越高。同时, c 值的选取对于变量的划分也有着较大的影响,表3为 c 值分别取1.2、1.3和1.4时相关变量子块与独立变量子块的划分结果,由表3可知当 c 选取1.2与1.3时变量子块划分结果相同,当 c 选取1.4时变量2被划分到独立变量子块中去,但由图3的柱高可看出,变量2柱高较高,需要将其划分到相关变量中,因此本文选择随机因子 c 为1.3。




图3 监测变量的互信息值

Fig. 3 Mutual information values of the monitoring variables

表4、5为DPCA、TNPE、DLV、SVDD和KDLV-DWSVDD 5种算法在青霉素发酵过程仿真验证的故障检测率和故障误报率,由表4、5可知,本文所提KDLV-DWSVDD算法相较于其他4种算法有较好的故障检测

表3 变量划分结果

Table 3 Variable partitioning results

C 值	相关变量子块	独立变量子块
1.2	2,4,6,7,8	1,3,9,10
1.3	2,4,5,6,7,8	1,3,9,10
1.4	4,5,6,7,8	1,2,3,9,10

效果,为进一步说明本文所提算法的有效性,给出5种算法在表2中故障1和4工况下的监控图,如图4、5所示,图中虚线代表统计量控制限,实线代表统计量值。

图4为5种算法在故障1下的故障监控图。图4(a)为TNPE算法在故障1下第100采样点加入阶跃故障时的 T^2 和 SPE 监控图, T^2 和 SPE 均能迅速检测出故障,但 T^2 在0~50点之间产生较多误报,且在100~300点之间产生较多漏报;图4(b)为DPCA算法在故障1下的 T^2 和 SPE 监控图, T^2 和 SPE 均能迅速检测出故障,但 T^2 和 SPE 在0~50点之间均产生较多误报;图4(c)为DLV算法在故障1下的 T^2 和 SPE 监控图, T^2 和 SPE 均能有效地检测出故障,但 T_d^2 在0~50点之间产生较多误报, T_s^2 和 SPE 在0~50点和300~400点之间产生较多误报,且 SPE 在100~300点之间产生较多漏报;图4(d)为SVDD算法在故障1下的 R^2 监控图, R^2 能有效检测出故障,且全程无误报,但在100~300点之间产生少量漏报;图4(e)

表 4 5 种方法的 8 个故障批次的故障检测率
Table 4 The fault detection rates of 8 fault batches for five methods

故障 序号	TNPE		DPCA		DLV			SVDD	KDLV-DWSVDD			
	SPE	T ²	SPE	T ²	SPE	T _d ²	T _s ²	R ²	SPE	T _d ²	T _s ²	R ²
1	1	0.95	1	1	0.535	1	1	0.91	0	0	0	1
2	1	1	1	1	1	0.980	1	0.82	1	1	0.960	0.03
3	0.820	0.95	0.740	0.91	0.830	0.720	0.800	0.83	0.095	0.150	0.190	0.88
4	0.535	0.74	0.445	0.76	0.110	0.695	0.565	0.53	0.795	0.695	0.455	0
5	0.725	0.47	0.900	0.74	0.135	0.765	0.965	0.70	0.590	0.755	0.480	0.73
6	0.930	0.91	0.940	0.94	0.910	0.840	0.870	0.92	0.330	0.270	0.230	0.96
7	0.080	0.18	0.040	0.24	0.450	0.510	0.450	0.31	0.880	0.940	0.870	0.03
8	0.755	0.52	0.900	0.77	0.270	0.790	0.900	0.77	0.610	0.900	0.550	0.82


表 5 5 种方法的 8 个故障批次的故障误报率
Table 5 Fault false alarm rates of 8 fault batches for five methods

故障 序号	TNPE		DPCA		DLV			SVDD	KDLV-DWSVDD			
	SPE	T ²	SPE	T ²	SPE	T _d ²	T _s ²	R ²	SPE	T _d ²	T _s ²	R ²
1	0.010	0.220	0.030	0.045	0.105	0.450	0.335	0.010	0	0.030	0	0
2	0.030	0.110	0.020	0.045	0.020	0.010	0	0.115	0.014	0.010	0.005	0
3	0.010	0.325	0.045	0.075	0.025	0.300	0.010	0.010	0.010	0.015	0.010	0.01
4	0.050	0.185	0.030	0.060	0.030	0.055	0	0.050	0.020	0.130	0.050	0.01
5	0.505	0.135	0.535	0.545	0.150	0.530	0.705	0.510	0.505	0.505	0.550	0.44
6	0.080	0.200	0.110	0.100	0.240	0.040	0.030	0.060	0.190	0.030	0.150	0.01
7	0.060	0.250	0.130	0.135	0.250	0.050	0.080	0.020	0.030	0.100	0.040	0.02
8	0.550	0.230	0.530	0.550	0.170	0.580	0.715	0.510	0.515	0.505	0.560	0.45


为 KDLV-DWSVDD 算法在故障 1 下的 T²、SPE 和 R² 监控图, T² 和 SPE 不能检测出故障, 而 R² 能迅速检测出故障, 且全程无漏报误报。通过过程变量的分块结果可知, 通风速率被划分在独立变量子块中, 而阶跃故障 1 则发生在独立变量中, 相较于其他 4 种算法将相关变量和独立变量视为一个整体进行过程监控, KDLV-DWSVDD 算法将过程变量按照相关性进行了区分, 当故障发生在独立变量中时, 没有其它无关变量对于检测结果的影响, 在独立变量子块中 DWSVDD 算法的检测结果优于其他 4 种算法且无漏报误报, 检测结果更好。

图 5 为 5 种算法在故障 4 下的故障监控图。图 5(a) 为 TNPE 算法在故障 4 下第 100 采样点加入斜坡故障时的 T² 和 SPE 监控图, T² 在第 152 采样点处检测出故障, 在第 0~50 采样点间存在较多误报, SPE 在第 193 采样点处检测出故障; 图 5(b) 为 DPCA 算法在故障 5 下的 T² 和 SPE 监控图, T² 在第 148 采样点处检测出故障, 在第 0~50 采样点间存在少量误报, SPE 在第 211 采样点处检测出故障, 在第 0~50 采样点间存在少量误报; 图 5(c) 为

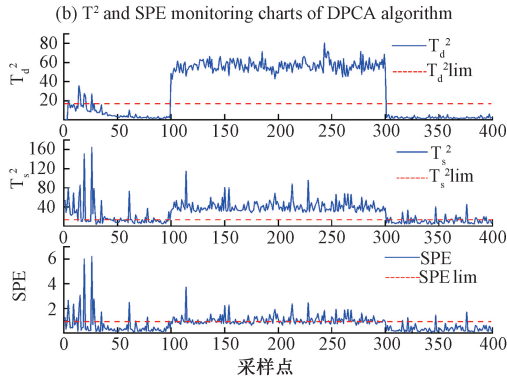
DLV 算法在故障 4 下的 T² 和 SPE 监控图, T_d² 在第 161 采样点处检测出故障, T_s² 在第 187 采样点处检测出故障, 但全程存在较多误报, SPE 在第 278 采样点处检测出故障; 图 5(d) 为 SVDD 算法在故障 4 下的 R² 监控图, R² 在第 194 采样点处检测出故障; 图 5(e) 为 KDLV-DWSVDD 算法在故障 4 下的 T²、SPE 和 R² 监控图, T_d² 在第 161 采样点处检测出故障, T_s² 在第 209 采样点处检



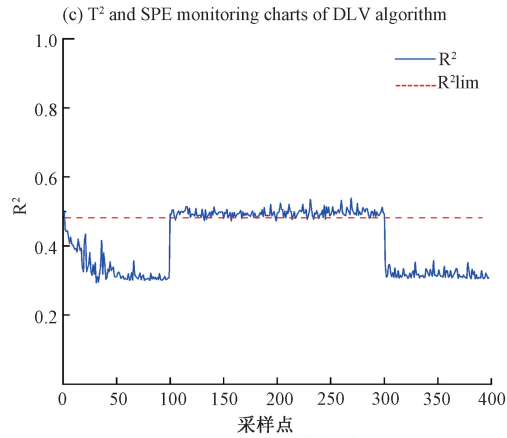
(a) TNPE 算法 T² 和 SPE 监控图
(a) T² and SPE monitoring charts of TNPE algorithm



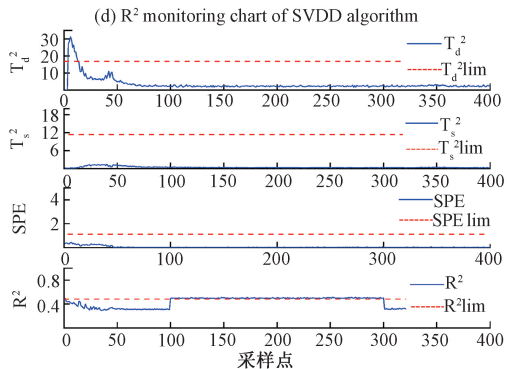
(b) DPCA算法T²和SPE监控图



(c) DLV算法T²和SPE监控图

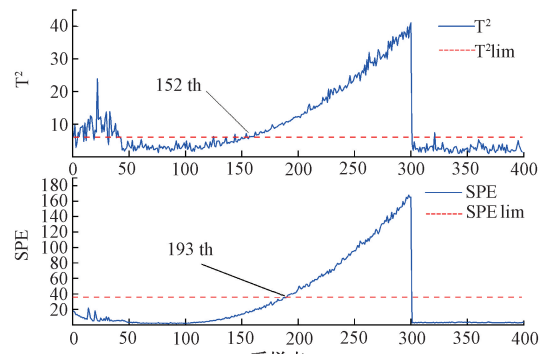


(d) SVDD算法R²监控图

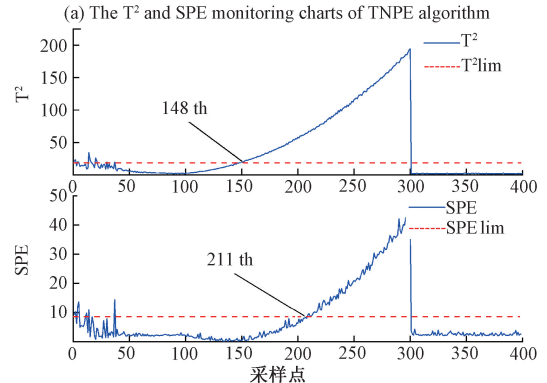


(e) KDLV-DWSVDD算法T²、SPE和R²监控图


(e) T², SPE and R² monitoring charts of KDLV-DWSVDD algorithm



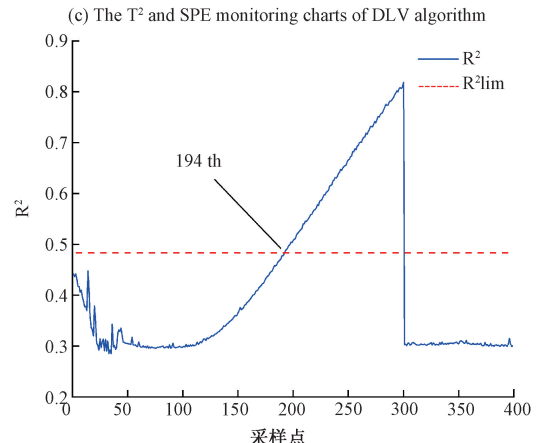
(a) TNPE算法T²和SPE监控图



(b) DPCA算法T²和SPE监控图



(c) DLV算法T²和SPE监控图




(d) SVDD算法R²监控图

(d) The R² monitoring chart of SVDD algorithm

图4 青霉素发酵过程故障1的检测效果

Fig. 4 Detection effect of fault 1 in the penicillin fermentation process



(e) KDLV-DWSVDD算法 T^2 、SPE和 R^2 监控图

(e) The T^2 , SPE and R^2 monitoring charts of KDLV-DWSVDD algorithm

图 5 青霉素发酵过程故障 4 的检测效果

Fig. 5 Detection effect of fault 4 in the penicillin fermentation process

测出故障, SPE 在第 141 采样点处检测出故障, 由于故障变量存在于相关变量中, R^2 不能检测出故障。对于斜坡故障 4 来说, 5 种算法都不能在故障发生时立即检测出故障, 这种检测延迟的主要原因是搅拌功率的斜坡故障在生产过程中传播速度较慢, 相较于阶跃故障, 斜坡故障由于其过程变量缓慢变化不能立即显现, 而与其他算法相比, KDLV-DWSVDD 算法能够及时检测到故障的发生且误报率较少, 故障检测性能更好, 在保持 KDLV 和 DWSVDD 算法优点的同时可以迅速判断故障存在于独立变量或相关变量之中。

表 6 对比了 5 种算法的性能, 相较于 DPCA 算法、TNPE 算法提取动态信息和 DLV 算法提取动态潜变量, KDLV-DWSVDD 算法在进行相关变量和独立变量分块的基础上需要完成核映射和动态潜变量提取, 由于核方法的引入需要计算核矩阵, 高斯核需要计算二范数及 \exp 运算, 故计算量较大, 但也因为核方法的引入使得所提算法对于线性、非线性输入都能有较好的处理效果, 同时, 由于核方法的计算很大程度上取决于总体样本的个数, 对于样本的维数依赖较小, 本文所提算法利用互信息将过程变量分为相关变量和独立变量, 在一定程度上减少了样本的大小, 相较于对整体采用 KDLV 算法, 仅在相关变量中采用 KDLV 算法使得计算量在一定程度上减小。但总体而言, 所提算法的计算复杂度相比 4 种对比算法仍然较高, 如何改善核参数的选取及提高算法的运行效率也是下一步研究的目标。

本文采用一个工业案例-半导体 AI 堆蚀刻过程验证所提算法在实际工业过程中的效果^[3], 该过程数据集由 LAM 金属蚀刻机在蚀刻 129 个硅片的过程中的工程变量组成, 包含 108 个正常硅片、21 个故障硅片。故障通

表 6 5 种方法性能对比

Table 6 Performance comparison of five methods

	动态性	非线性	区分动态、静态信息	区分相关、独立变量	时间复杂度
DPCA	✓	×	×	×	低
TNPE	✓	×	×	×	低
SVDD	×	✓	×	×	低
DLV	✓	×	✓	×	较高
本文算法	✓	✓	✓	✓	较高

过改变压力、TCP 功率、 Cl_2 等来添加。本文主要选择 17 个过程变量共 40 批数据, 每一批长度为 100, 组成训练数据集 $X(40 \times 17 \times 100)$, 17 个过程变量如表 7 所示。按照 2.1 节描述的变量划分方法, 取 $c = 1.2$, 其中, 变量 1、2、3、5、7、14、15 被划分为独立变量, 变量 4、6、8、9、10、11、12、13、16、17 被划分为相关变量。

表 7 半导体制造过程的 17 个过程变量

Table 7 17 process variables in the semiconductor manufacturing process

变量序号	过程变量	变量序号	过程变量
1	BCl_3 流量	10	RF 功率
2	Cl_2 流量	11	RF 阻抗
3	RF 底部功率	12	TCP 调谐
4	A 检测端点 2	13	TCP 相位误差
5	氦压力	14	TCP 阻抗
6	室压	15	TCP 顶部功率
7	RF 调谐	16	TCP 负荷
8	RF 负荷	17	Vat 阀
9	相位误差	-	-

本文分别用 DLV 算法、SVDD 算法和 KDLV-DWSVDD 算法来对故障 14 和故障 16 进行监控, 结果如图 6、7 所示。

图 6 为 DLV、SVDD 和 KDLV-DWSVDD 算法对故障 14 的监控图, 故障 14 属于室压故障, 位于独立变量中, 从图 6 中可以看出, DLV 算法的 T_d^2 统计量几乎不能检测出故障的发生, T_s^2 统计量虽然能较多的检测出故障的发生, 但存在着较多的漏报, SPE 统计量仅在 0~50 采样点之间能检测出故障的发生, 50~100 采样点之间检测效果较差; SVDD 算法虽然能在 0~65 之间检测出故障的发生, 但其间存在较多漏报, 且 65~100 采样点之间检测效果较差; 由于对变量进行了划分, 分别采用不同的监控方法, 因此, 针对独立变量中发生的故障, KDLV-DWSVDD 算法中的 R^2 统计量表现出了良好的故障检测

效果,几乎全程都能检测到故障的发生,且只有极少的故障没有被检测到。

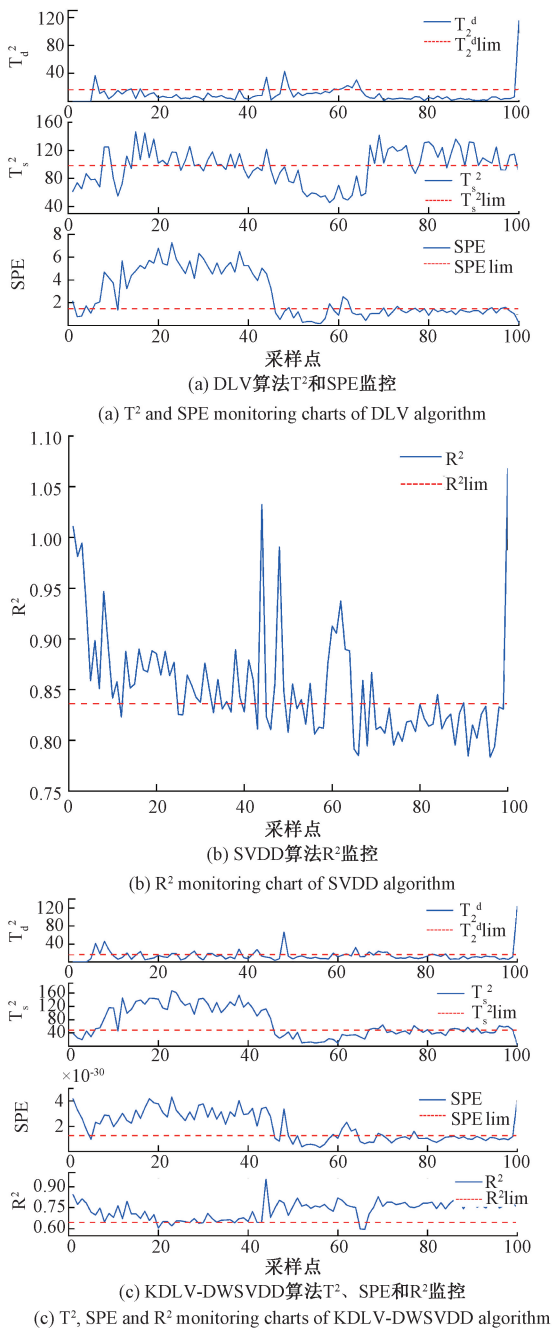


图6 3种算法对故障14的监控图

Fig. 6 Monitoring charts of fault 14 for three algorithms

图7为DLV、SVDD和KDLV-DWSVDD算法对故障16的监控图,故障16属于TCP故障,位于相关变量中,从图7中可以看出,DLV算法的 T_s^2 和SPE统计量虽然能较多的检测出故障的发生,但在45~75采样点间存在着较多的漏报;SVDD算法检测效果较好,但在20~40

采样点之间存在较多漏报;针对相关变量中发生的故障,KDLV-DWSVDD算法中的 T^2 和SPE统计量表现出了良好的故障检测效果, T_d^2 和SPE统计量检测时只有极少故障未被检测到, T_s^2 几乎全程都能检测到故障的发生。对比DLV算法与SVDD算法,KDLV-DWSVDD算法检测效果最佳。

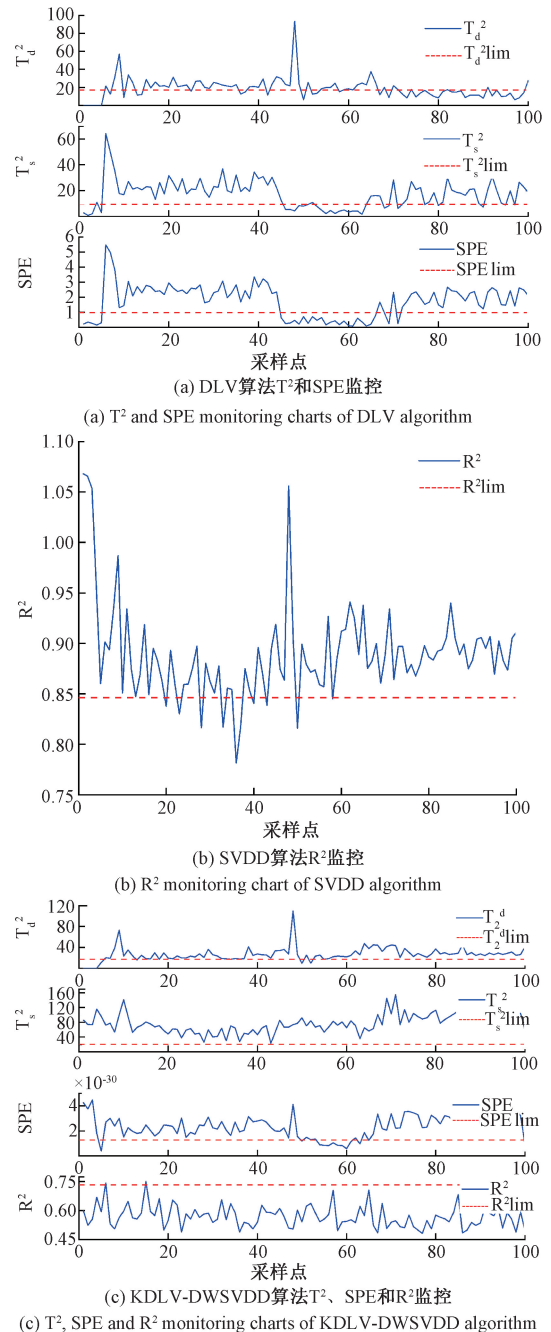


图7 3种算法对故障16的监控图

Fig. 7 Monitoring charts of fault 16 for three algorithms

5 结 论

本文提出了一种基于变量分块的 KDLV-DWSVDD 的间歇过程故障检测算法。考虑到动态过程变量间的交叉相关性且不同测量变量会存在不同的自相关性,该算法通过互信息的方法将相关变量和独立变量进行分离,在此基础上得到的变量子块能够较好的解决复杂动态过程在不同时滞上的相关性交错问题。在相关变量子块中,使用 KDLV 算法提取过程的动态信息和静态信息,提升了相关变量的故障检测效果;对独立变量子块首先通过时序扩展引入增广矩阵提取动态信息,之后通过权值矩阵增强有用信息并抑制噪声,提升了独立变量的故障检测效果。通过青霉素发酵过程和半导体制造实际工业过程验证了基于变量分块的 KDLV-DWSVDD 算法在间歇过程检测中的优越性。

参考文献

- [1] 彭开香, 马亮, 张凯. 复杂工业过程质量相关的故障检测与诊断技术综述[J]. 自动化学报, 2017, 43(3): 349-365.
PENG K X, MA L, ZHANG K. Review of quality-related fault detection and diagnosis techniques for complex industrial process[J]. Acta Automatica Sinica, 2017, 43(3): 349-365.
- [2] 李晗, 萧德云. 基于数据驱动的故障诊断方法综述[J]. 控制与决策, 2011, 26(1): 1-9.
LI H, XIAO D Y. Survey on data driven fault diagnosis methods[J]. Control and Decision, 2011, 26(1): 1-9.
- [3] 赵小强, 惠永永. 基于 WICA-WGNPE 的高斯-非高斯联合指标间歇过程监控[J]. 仪器仪表学报, 2018, 39(1): 190-199.
ZHAO X Q, HUI Y Y. Batch process monitoring with Gaussian and non-Gaussian joint indicator based on WICA-WGNPE [J]. Chinese Journal of Scientific Instrument, 2018, 39(1): 190-199.
- [4] KU W, STORER R H, GEORGAKIS C. Disturbance detection and isolation by dynamic principal component analysis[J]. Chemometrics and Intelligent Laboratory Systems, 1995, 30(1): 179-196.
- [5] 苗爱敏, 葛志强, 宋执环, 等. 基于时序扩展的邻域保持嵌入算法及其在故障检测中的应用[J]. 华东理工大学学报(自然科学版), 2014(2): 218-224.
MIAO AI M, GE ZH Q, SONG ZH H, et al. Neighborhood preserving embedding based on temporal extension and its application in fault detection[J]. Journal of East China University of Science and Technology (Natural Science Edition), 2014(2): 218-224.
- [6] LI G, QIN S J, ZHOU D. A new method of dynamic latent-variable modeling for process monitoring[J]. IEEE Transactions on Industrial Electronics, 2014, 61(11): 6438-6445.
- [7] 唐俊苗, 俞海珍, 史旭华, 等. 基于潜变量自回归算法的化工过程动态监测方法[J]. 化工学报, 2019, 70(3): 987-994.
TANG J M, YU H ZH, SHI X H, et al. Dynamic monitoring of chemical processes based on latent variable auto-regressive algorithm [J]. CIESC Journal, 2019, 70(3): 987-994.
- [8] ZHOU L, LI G, SONG Z, et al. Autoregressive dynamic latent variable models for process monitoring[J]. IEEE Transactions on Control Systems Technology, 2016, 25(1): 366-373.
- [9] ZHENG J, ZHOU L, GE Z, et al. Switching autoregressive dynamic latent variable model for fault detection in multimode processes [C]. 2017 6th Data Driven Control and Learning Systems (DDCLS), IEEE, 2017: 617-622.
- [10] 王斐, 房立清, 赵玉龙, 等. 基于 VMD 和 SVDD 的滚动轴承早期微弱故障检测和性能退化评估研究[J]. 振动与冲击, 2019, 38(22): 224-230.
WANG F, FANG L Q, ZHAO Y L, et al. Rolling bearing early weak fault detection and performance degradation assessment based on VMD and SVDD [J]. Journal of Vibration and Shock, 2019, 38(22): 224-230.
- [11] 杨健健, 唐至威, 王晓林, 等. 单类学习下基于 VSAPSO-BP 的掘进机异常检测方法[J]. 振动. 测试与诊断, 2019, 39(1): 130-135.
YANG J J, TANG ZH W, WANG X L, et al. Roadheader anomaly detection method based on VSAPSO-BP under the single category learning [J]. Journal of Vibration, Measurement & Diagnosis, 2019, 39(1): 130-135.
- [12] HUANG J, ERSOY O K, YAN X. Fault detection in dynamic plant-wide process by multi-block slow feature analysis and support vector data description [J]. ISA Transactions, 2019, 85: 119-128.
- [13] TAN J, FU W, WANG K, et al. Fault diagnosis for rolling bearing based on semi-supervised clustering and support vector data description with adaptive parameter optimization and improved decision strategy[J]. Applied Sciences, 2019, 9(8): 1676-1697.
- [14] 祝志博, 王培良, 宋执环. 基于 PCA-SVDD 的故障检测和自学习辨识[J]. 浙江大学学报(工学版), 2010(4): 652-658.

- ZHU ZH B, WANG P L, SONG ZH H. PCA-SVDD based fault detection and self-learning identification[J]. Journal of Zhejiang University (Engineering Science), 2010(4): 652-658.
- [15] 王晶, 魏华彤, 曹柳林, 等. 基于 SVDD 时段细化的间歇过程故障监控[J]. 清华大学学报(自然科学版), 2012(9): 1176-1181.
WANG J, WEI H T, CAO L L, et al. Fault monitoring of batch processes based on SVDD sub-stage segmentation[J]. Journal of Tsinghua University (Science and Technology), 2012(9): 1176-1181.
- [16] 姚旭, 王晓丹, 张玉玺, 等. 特征选择方法综述[J]. 控制与决策, 2012, 27(2): 161-166.
YAO X, WANG X D, ZHANG Y X, et al. Summary of feature selection algorithms[J]. Control and Decision, 2012, 27(2): 161-166.
- [17] HAN M, REN W, LIU X. Joint mutual information-based input variable selection for multivariate time series modeling [J]. Engineering Applications of Artificial Intelligence, 2015, 37: 250-257.
- [18] JIANG Q, YAN X. Plant-wide process monitoring based on mutual information-multiblock principal component analysis [J]. ISA Transactions, 2014, 53 (5): 1516-1527.
- [19] HUANG J, YAN X. Related and independent variable fault detection based on KPCA and SVDD[J]. Journal of Process Control, 2016, 39: 88-99.
- [20] 于蕾, 邓晓刚, 曹玉苹, 等. 基于变量分组 DTW-MCVA 的不等长间歇过程故障检测方法[J]. 化工学报, 2019, 70(9): 3441-3448.
YU L, DENG X G, CAO Y P, et al. Fault detection method of unequal-length batch process based on VGDTW-MCVA [J]. CIESC Journal, 2019, 70 (9): 3441-3448.
- [21] HE X, CAI D, YAN S, et al. Neighborhood preserving embedding[C]. Tenth IEEE International Conference on Computer Vision, IEEE, 2005, 2: 1208-1213.
- [22] 陈法法, 杨晓青, 陈保家, 等. 基于正交邻域保持嵌入与多核相关向量机的滚动轴承早期故障诊断[J]. 计算机集成制造系统, 2018, 24(8): 1946-1954.
CHEN F F, YANG X Q, CHEN B J, et al. Early fault diagnosis of rolling bearing based on orthogonal neighborhood preserving embedding and multi-kernel relevance vector machine [J]. Computer Integrated Manufacturing Systems, 2018, 24(8): 1946-1954.

作者简介



赵小强 (通信作者), 2006 年于浙江大学获得博士学位, 现为兰州理工大学教授、博士生导师, 主要研究方向为过程监控与故障诊断, 生产调度、数据挖掘等。

E-mail: xqzhao@lut.cn

Zhao Xiaoqiang (Corresponding author)

received his Ph. D. degree from Zhejiang University in 2006. Now, he is a professor and Ph. D. supervisor in Lanzhou University of Technology. His main research interest includes process monitoring and fault diagnosis, production scheduling, and data mining.



牟淼, 2018 年于兰州理工大学获得学士学位, 现为兰州理工大学硕士研究生, 主要研究方向为过程监控与故障诊断。

E-mail: 916061824@qq.com

Mou Miao received his B. Sc. degree from Lanzhou University of Technology in 2018.

Now, he is a master student in Lanzhou University of Technology. His main research interest includes process monitoring and fault diagnosis.