

文章编号: 1008-1542(2021)04-0369-11

开放科学(资源服务)标识码(OSID):



# 基于 DW-ICA-SVM 的工业过程故障检测算法

郭金玉, 李 涛, 李 元

(沈阳化工大学信息工程学院, 辽宁沈阳 110142)

**摘要:** 为了有效提高支持向量机(SVM)算法的故障检测和监视性能, 提出一种新的基于 DW-ICA-SVM 的工业过程故障检测算法。首先, 对训练数据进行标准化, 运用独立元分析(ICA)获取数据的独立元矩阵, 提取隐藏的非高斯信息。其次, 运用杜宾-瓦特森(Durbin-Watson, DW)准则计算独立元(ICs)的 DW 值, 通过 DW 方法有效提取重要噪声信息, 选取重要的 ICs。再次, 将包含重要信息的 ICs 作为 SVM 模型的输入, 获得判别分类函数, 将测试数据的 ICs 输入该模型, 对其进行故障检测和监视。最后, 将新算法运用于非线性数值例子和田纳西-伊斯曼工业过程, 并与 PCA, LPP, ICA, SVM 和 ICA-SVM 方法进行比较。结果表明, 所提方法降低了样本间的自相关性, 有效提高了故障检测率。因此, 新算法在一定程度上加强了对隐藏非高斯信息的提取与识别, 为提高 SVM 算法在工业过程故障检测中的应用性能提供了参考。

**关键词:** 自动控制技术其他学科; 故障检测; 杜宾-瓦特森准则; 独立元分析; 支持向量机

中图分类号: TP277

文献标识码: A

doi: 10.7535/hbkd.2021yx04007

## Fault detection algorithm of industrial process based on DW-ICA-SVM

GUO Jinyu, LI Tao, LI Yuan

(College of Information Engineering, Shenyang University of Chemical Technology, Shenyang, Liaoning 110142, China)

**Abstract:** In order to effectively improve the fault detection and monitoring performance of support vector machine (SVM) algorithm, a new fault detection algorithm of industrial process based on DW-ICA-SVM was proposed. Firstly, the training data was normalized. The independent component analysis (ICA) was used to obtain the independent component matrix of the data and extract the hidden non-Gaussian information. Then the Durbin-Watson (DW) criterion was used to calculate the DW values of the independent components (ICs). The DW method was used to effectively extract important noise information and select the important ICs. The ICs containing important information were used as the input of the SVM model to obtain the discriminant classification function. The ICs of test data were input to the model for fault detection and monitoring. Finally, the method was applied to the nonlinear numerical example and the Tennessee-Eastman industrial process, and compared with

收稿日期: 2021-03-23; 修回日期: 2021-05-17; 责任编辑: 冯 民

基金项目: 国家自然科学基金(61490701, 61673279); 辽宁省教育厅一般项目(LJ2019007)

第一作者简介: 郭金玉(1975—), 女, 山东高唐人, 副教授, 博士, 主要从事工业过程的故障检测与诊断、生物特征识别算法及应用方面的研究。

通讯作者: 李 元教授。E-mail: li-yuan@mail.tsinghua.edu.cn

郭金玉, 李涛, 李元. 基于 DW-ICA-SVM 的工业过程故障检测算法[J]. 河北科技大学学报, 2021, 42(4): 369-379.

GUO Jinyu, LI Tao, LI Yuan. Fault detection algorithm of industrial process based on DW-ICA-SVM[J]. Journal of Hebei University of Science and Technology, 2021, 42(4): 369-379.

PCA, LPP, ICA, SVM and ICA-SVM methods. The results show that the proposed method reduces the autocorrelation among samples and effectively improves the fault detection rate. The proposed method strengthens the extraction and recognition of hidden non-Gaussian information to a certain extent, and provides a reference for improving the performance of SVM algorithm in fault detection of industrial process.

**Keywords:** other disciplines of automatic control technology; fault detection; Durbin-Watson criterion; independent component analysis; support vector machine

在大数据时代背景下,工业自动化技术得到快速发展,工业系统的规模和控制系统的复杂程度都在不断提高,但同时也造成故障发生概率的不断增大,因此对控制系统精度和安全性提出了更高要求。现代工业系统中需要建立具备高性能的监控系统来监视系统的运行状态,以便快速有效地检测出系统故障<sup>[1-5]</sup>。近年来,基于数据驱动的故障检测技术在工业过程中得到广泛应用,该研究方向也成为国内外众多学者的研究重点。

主元分析(principal component analysis, PCA)<sup>[6-7]</sup>方法广泛应用于工业生产过程故障检测和监视,由于 PCA 是一种线性算法,因此具有一定的局限性。为了解决 PCA 在非线性过程中的监控问题,基于核理论的主元分析(kernel principal component analysis, KPCA)方法被提出,用以解决非线性过程的实时监控与检测<sup>[8-10]</sup>。PCA 和 KPCA 等算法提取的是数据的全局特征,会丢失数据的局部结构信息,导致故障检测性能降低。为了改善 PCA 和 KPCA 等全局算法在故障检测中的不足, HU 等<sup>[11]</sup>将局部保持投影算法(locality preserving projections, LPP)应用于工业过程故障检测,它可以很好地保持数据中近邻点之间的结构信息,保留数据的局部特征,提高故障检测性能。PCA 和 LPP 应用  $T^2$  和 SPE 两个统计量进行过程状态监控。 $T^2$  和 SPE 能够较好地完成过程监控的前提条件是变量服从多元高斯分布且样本间相互独立。事实上,众多工业生产过程变量间存在较强的非线性、非高斯特征<sup>[12]</sup>。为了提高非高斯过程的故障检测效果, KANO 等<sup>[13]</sup>将独立主元分析(independent component analysis, ICA)应用于故障检测领域。ICA 区别于其他方法的特点在于运用 ICA 方法能够使每个分量最大化独立。ICA 方法不仅充分利用了高阶统计量,而且能够从数据中有效提取出相互独立的隐藏变量,这些隐藏变量能够更好地反映出数据的变化特征,最大程度地捕获有效信息。但是传统 ICA 在提取非高斯隐藏信息时,容易丢失数据的高斯信息以及部分样本特征,同时数据间的自相关性也会导致 ICA 对部分过程数据的检测效果不理想。

支持向量机(support vector machine, SVM)方法<sup>[14-16]</sup>作为机器学习的经典算法,在解决小样本和非线性的故障检测问题时具有很多优势,因此被广泛应用于故障检测与诊断领域。SVM 方法通过寻找空间最大分离超平面,实现将不同类别的数据有效分离。值得注意的是, SVM 方法在进行模型训练时,需要加入正常数据和故障数据。经过训练, SVM 模型能有效学习到故障数据的特征变化特点,因此在模型测试时能够保持较高的精确度。为了提高 SVM 算法对故障的快速精准识别, ONEL 等<sup>[17]</sup>对对偶 C 参数 SVM (C-parameterized SVM, C-SVM) 目标函数灵敏度分析中推导出特征选择算法,用于故障特征的提取和快速诊断,同时能够减少有效信息损失,提高了故障检测和诊断性能。由于故障检测与诊断存在非线性问题, XUE 等<sup>[18]</sup>引入高斯核支持向量机递归特征消除(support vector machine recursive feature elimination, SVM-RFE)算法提取非线性特征进行故障检测与诊断,该方法关键在于核参数的选择,通过对比选择出最优参数,建立一种先进的故障检测与诊断框架。此外,为了提高 SVM 算法的故障监视性能, JI 等<sup>[19]</sup>运用独立元分析提取隐藏独立分量并与 SVM 方法结合,对故障作出有效检测和诊断。为了进一步改进 ICA-SVM 方法的故障检测性能, HSU 等<sup>[20]</sup>将 ICA 与 SVM 结合,利用 ICA 获取隐藏噪声信息,计算  $T^2$  统计量并引入时滞和时差输入特性作为 SVM 输入,有效提高了 SVM 的故障检测性能以及对隐藏噪声信息的提取。

对高维数据, SVM 的运行时间较长。为了降低 SVM 的运行时间,需要对数据进行特征提取和降维,而 SVM 算法性能的高低依赖于数据特征提取的好坏。传统 ICA 算法运用累计方差贡献率选取独立元,但是无法消除过程变量间自相关性对故障检测性能的影响。针对此问题,本文提出一种基于 DW-ICA-SVM 的工业过程故障检测方法。

## 1 基于DW-ICA-SVM的工业过程故障检测

### 1.1 支持向量机(SVM)算法

SVM算法作为机器学习中的经典分类算法,在解决数据集规模相对较小或样本非线性问题方面具有许多优点。对线性数据,SVM能够建立最大分离超平面对数据进行分类;对非线性问题,需要将数据投影到高维空间,去除数据非线性,建立最大分离超平面,使数据能够进行有效分类。

假设样本训练数据集为  $H = \{(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_m, y_m)\}$ ,  $y_i \in \{-1, +1\}$ , 在该样本训练集空间中找到一个最大分离超平面,把不同类别的样本有效分类,这是分类学习最基本的思想。SVM对指定数据分类的超平面如下:

$$\mathbf{w}^T \mathbf{x} + b = 0, \quad (1)$$

式中:  $\mathbf{w} = (w_1, w_2, \dots, w_d)$  是权重向量;  $b$  是位移项。为了找到最大间隔的超平面,实现最大程度分类,需要找到合适的参数  $\mathbf{w}$  和  $b$ , 使得间隔  $\gamma$  最大。考虑到一些无法分类的样本以及支持向量机在一些样本上分类出错的情况,为了提高支持向量机的容错率,引入惩罚变量  $C$  和松弛变量  $\xi$ 。松弛变量的引入使 SVM 分类具有一定的容错性,能够忽略落在隔离带中的样本点对超平面划分的影响,使超平面不用朝这些样本点方向移动。惩罚变量通常设置为一个常数,惩罚变量越大,要求松弛变量的值尽量小,即对噪声的容忍度越小,其主要起到权衡的作用。SVM的基本型可表示为

$$\min_{\mathbf{w}, b, \xi} \left( \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^m \xi_i \right), \quad (2)$$

$$\text{s.t. } y_i (\mathbf{w}^T \mathbf{x}_i + b) \geq 1 - \xi_i, \quad i = 1, 2, \dots, m,$$

式中:  $\xi_i \geq 0$ ;  $C > 0$ , 是一个常数。

为了求解式(2),需要将其转化为“对偶问题”,运用拉格朗日乘法求解,则该问题的拉格朗日函数可写为

$$L(\mathbf{w}, b, \alpha, \xi, \mu) = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^m \xi_i + \sum_{i=1}^m \alpha_i (1 - \xi_i - y_i (\mathbf{w}^T \mathbf{x}_i + b)) - \sum_{i=1}^m \mu_i \xi_i. \quad (3)$$

其中  $\alpha_i \geq 0$ ,  $\mu_i \geq 0$  是拉格朗日乘子。通过对上式求解,可以得到该模型为

$$f(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + b = \sum_{i=1}^m \alpha_i y_i \mathbf{x}_i^T \mathbf{x} + b. \quad (4)$$

在实际工业过程中,数据并不只是服从线性分布,更多情况是非线性数据。为了对数据更好地分类,需要通过非线性映射  $\varphi(x)$  将其投影到高维特征空间。为了避免高维运算,引入核函数,通过核函数计算后该模型为

$$f(\mathbf{x}) = \text{sign} \left( \sum_{i,j=1}^m \alpha_i y_i K(\mathbf{x}_i, \mathbf{x}_j) + b \right). \quad (5)$$

因此,SVM在对数据进行分类时,若数据是线性分布,则SVM对其进行线性分类;若数据是非线性分布,则SVM将其映射到高维空间,并引入核函数解决高维计算问题,进而高效准确地对数据实现分类。因此,本文使用SVM作为故障分类器,实现对数据的有效检测。

### 1.2 DW-ICA-SVM算法

假设  $\bar{\mathbf{x}} \in \mathbf{R}^{m \times n}$  为观测样本,其中包含  $n$  个变量。首先需要对原始数据进行标准化处理,将其处理为均值为0、方差为1的数据,消除数据间的量纲影响。标准化后的数据矩阵为  $\mathbf{x}$ , ICA对其分解为

$$\mathbf{x} = \mathbf{A}\mathbf{s} + \mathbf{E}, \quad (6)$$

式中:  $\mathbf{A} \in \mathbf{R}^{r \times n}$  是未知的混合矩阵;  $\mathbf{s} \in \mathbf{R}^{l \times r}$  是独立元向量;  $\mathbf{E} \in \mathbf{R}^{l \times n}$  是误差向量,且  $r \leq n$ 。ICA方法通过观测样本估计出  $\mathbf{A}$  和  $\mathbf{s}$ , 进一步计算出分离矩阵  $\mathbf{W}$  和重构后的独立元向量  $\hat{\mathbf{s}}$ , 使其满足:

$$\hat{\mathbf{s}} = \mathbf{x}\mathbf{W}. \quad (7)$$

ICA算法需要对数据进行中心化和白化处理,使观测变量的协方差矩阵为单位阵。白化预处理即对中心化后  $\mathbf{x}$  的协方差矩阵进行奇异值分解,

$$\mathbf{E}\{\mathbf{x}^T \mathbf{x}\} = \mathbf{U}\mathbf{\Lambda}\mathbf{U}^T, \quad (8)$$

式中:  $\mathbf{U}$  为特征值对应的特征向量组成的矩阵;  $\mathbf{\Lambda}$  为  $\mathbf{x}$  协方差矩阵的特征值组成的对角阵。

计算

$$z = Qx, \tag{9}$$

$$Q = \Lambda^{-\frac{1}{2}} U^T, \tag{10}$$

其中  $z$  为白化向量。可以得到

$$z = Qx = QAs = Bs, \tag{11}$$

其中  $B = QA$  为分离矩阵。于是,独立元  $s$  的估计值为

$$\hat{s} = Wx = B^T z = B^T Qx = B^T \Lambda^{-\frac{1}{2}} U^T x. \tag{12}$$

那么  $W$  和  $B$  的关系可表示为

$$W = B^T Q. \tag{13}$$

本文通过 FastICA 算法获取独立元矩阵,然后运用 DW 准则检验 IC 是否包含重要信息。相较于传统选择独立元个数的累计方差贡献率方法,DW 准则<sup>[21]</sup>能够客观地测量出变量的结构或非随机行为,因此能有效挖掘出重要的隐藏变量,优化模型的稳定性。根据式(14)能够计算各个变量的 DW 值,

$$DW = \frac{\sum_{i=2}^n (\delta x_i - \delta x_{i-1})^2}{\sum_{i=1}^n (\delta x_i \delta x_i)}. \tag{14}$$

式中:  $\delta x_i$  和  $\delta x_{i-1}$  是向量中连续点的残差; $n$  是变量数。最初 DW 准则被提出用于测量信噪比,在没有任何噪声的情况下,DW 的值会趋向于 0,如果信号只有噪声,DW 的值会趋向于 2。因此,本文采用 DW 值的色谱图方法来确定独立元个数。如果 IC 由噪声组成,即错误信息,则 DW 值较高,在色谱图中颜色较浅;否则,DW 值较低,在色谱图中颜色较深,那么这种 IC 被认为是重要的。提取出包含重要信息的独立元矩阵后,运用 SVM 模型对数据进行分类操作。

### 1.3 基于 DW-ICA-SVM 的工业过程故障检测步骤

基于 DW-ICA-SVM 算法的工业过程故障检测分为离线建模过程和在线检测 2 个步骤,流程图如图 1 所示。具体的操作步骤如下。

#### 1.3.1 建模过程

- 1) 获取正常操作条件的历史数据集  $X_1$  和故障操作条件下的历史数据集  $X_2$ ;
- 2) 对数据进行标准化,运用 ICA 方法获取独立元矩阵;
- 3) 根据式(14)计算每个独立元的 DW 值,进行升序排列。运用色谱图确定独立元个数,选取较小的 DW 值对应的独立元矩阵;
- 4) 将独立元矩阵作为 SVM 模型输入,训练 SVM 得到权重向量和位移。

#### 1.3.2 在线检测

- 1) 对新来的测试数据运用离线建模数据的均值和方差进行标准化;
- 2) 将标准化后的数据投影到 ICA 模型获得独立元矩阵;
- 3) 利用 DW 准则计算测试数据的 DW 值并排序;
- 4) 将较小 DW 值对应的独立元矩阵输入 SVM 模型进行故障分类。分类结果将正常数据定义为标签 0,故障数据定义为标签 1。

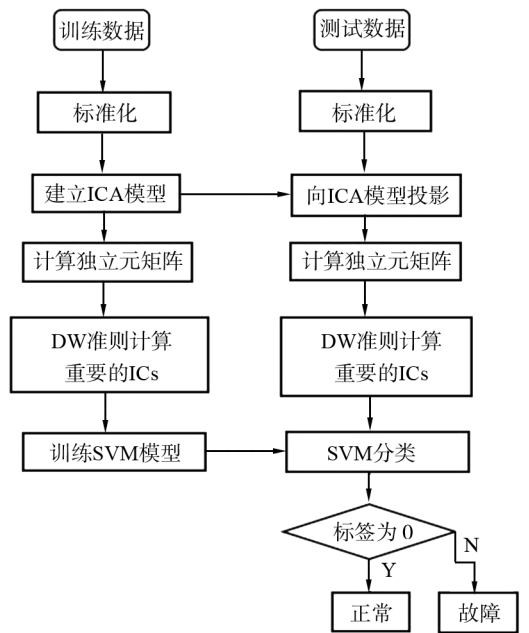


图 1 DW-ICA-SVM 方法故障检测流程图

Fig. 1 Flow chart of fault detection based on DW-ICA-SVM

## 2 仿真结果与分析

### 2.1 非线性数值例子

按照以下模型构造非线性数值例子<sup>[22]</sup>,该数据集包含 3 个变量:

$$\begin{cases} x_1 = t + e_1, \\ x_2 = t^2 - 2t + e_2, \\ x_3 = -t^3 + 3t^2 + e_3, \end{cases} \quad (15)$$

式中:  $t$  服从  $[0.01, 3]$  的均匀分布;  $e_1, e_2$  和  $e_3$  为服从均值为 0、标准差为 0.01 的正态分布的均匀噪声序列。在模型运行过程中,对变量 1 施加幅值为  $0.01 \times (i - 200)$  的扰动,其中  $i$  代表样本数量。对变量 2 和变量 3 分别施加幅值为 0.75 和  $-0.55$  的阶跃扰动组成该模型故障数据集。

本例中,选取 200 组正常样本和 200 组故障样本共同组成训练数据集,用于 DW-ICA-SVM 模型训练,再选取 100 组故障样本用于模型测试,验证模型有效性。将本文方法与 PCA, LPP, ICA, SVM 和 ICA-SVM 方法作比较,需要注意的是,ICA-SVM 方法需要计算出 ICA 的 3 个统计量  $I_a^2, I_e^2$  和 SPE,并将三者组合成矩阵作为 SVM 模型的输入,用于故障分类和检测。图 2 是样本散点图,“黑色星号”是正常样本,“红色圆圈”是故障样本,图中清晰地呈现出数据服从非线性分布。图 3 是变量  $x_1$  的分布图,从图中可以看出,该数据分布服从非高斯分布。因此,本文运用 DW-ICA 方法进行特征提取。




图 2 样本散点图

Fig. 2 Scatter plot of samples




图 3 变量  $x_1$  的分布图

Fig. 3 Distribution plot of variable  $x_1$

通过 DW 色谱图确定独立元的个数。图 4 是训练数据和故障数据不同变量的 DW 值。从图 4 可以清晰地看到,变量 1 和变量 3 的 DW 值相较于变量 2 较小,颜色较深,这 2 个变量包含了较多的隐藏信息,具有检测价值,是所需要的重要 ICs;而变量 2 的颜色较浅,DW 值较大,包含较多噪声信息。因此,在本例中,独立元个数选取 2 个。

图 5 是各种方法的故障检测结果图,其中“黑色圆圈”代表故障数据。PCA, LPP 和 ICA 方法运用 99% 控制限进行故障检测,控制限是由核密度估计方法<sup>[23]</sup>确定的。在 PCA, LPP, ICA 和 ICA-SVM 方法中独立元个数的选取采用 85% 的累计方差贡献率<sup>[24]</sup>来确定。对于 SVM,采用高斯核函数提高对非线性数据的处理能力。SVM 中需要调整惩罚因子  $C$ ,高斯核函数中需要调整窗宽  $g$ ,从而使分类器适应特定的

分类任务。对参数的选取,本文通过网格搜索方法得到参数的最优设置,将惩罚因子  $C$  设置为 0.8,窗宽  $g$  设置为 0.45。SVM, ICA-SVM 和 DW-ICA-SVM 方法的检测结果将正常数据定义为标签 0,故障数据定义为标签 1。从图 5 可以看出,传统算法 PCA, LPP 和 ICA 的检测效果并不理想,主要因为 PCA 是线性算法,对非线性过程检测效果不理想。LPP 算法的统计指标需要服从高斯分布的前提假设,当这种假设不满足时,会降低其检测性能。ICA 算法在提取隐藏非高斯信息时,容易丢失数据的高斯信息以及部分样本特征,同时数据间自相关性强弱也会导致 ICA 对部分过程数据的检测效果不理想。PCA 和 LPP 提取的是二阶统计信息,而 ICA 提取的是高阶统计信息,ICA 的检测效果好于 PCA 和 LPP。ICA-SVM 方法相较于 ICA,检






图 4 不同变量的 DW 值

Fig. 4 DW values of different variables


测效果具有一定的提升,这得益于 SVM 算法优秀的分类能力,能够将非线性数据映射到高维特征空间进行处理。SVM 和 DW-ICA-SVM 方法检测效果都很好,但是 DW-ICA-SVM 的检测结果要优于 SVM。




a) PCA  $T^2$ 数据




b) PCA SPE数据




c) LPP  $T^2$ 数据




d) LPP SPE数据




e) ICA  $I_d^2$ 数据



f) ICA  $I_e^2$ 数据



g) ICA SPE数据



h) SVM




图 5 6 种方法对非线性数值的检测结果

Fig. 5 Detection results of six methods for non-linear data

表 1 是各种算法对非线性数值例子的故障检测率对比。从表 1 可以看出,DW-ICA-SVM 的故障检测率高达 100%,相较于其他方法都有不同程度的提高。PCA,LPP 和 ICA 的检测结果并不理想,主要原因是这些算法的使用需要前提假设以及各自的使用范围不一样,并且数据的分布情况也会对检测结果有一定的影响。但是 SVM 具有较高的检测结果,这得益于 SVM 算法在训练数据时能够学习到 2 类样本的特征变化,因此在模型测试时能够对故障样本进行有效识别。

表 1 各种算法对非线性数值例子故障检测率对比

Tab.1 Comparisons of fault detection rate of various algorithms on nonlinear numerical example

单位:%

PCA		LPP		ICA			SVM	ICA-SVM	DW-ICA-SVM
$T^2$	SPE	$T^2$	SPE	$I_0^2$	$I_c^2$	SPE			
8	22	4	5	28	12.5	7	92	55	100

文献[25]指出,数据间的自相关性是影响故障检测性能的重要因素。本文 DW 方法能够选取样本间具有弱相关性的样本,剔除存在较强相关性的样本,减少相关性对数据故障检测性能的影响。图 6 是 ICA-SVM 和 DW-ICA-SVM 方法的样本相关性对比图。相较于 ICA,ICA-SVM 方法的检测效果有一定的提高,但并没有 SVM 的检测效果好。从图 6 可以看出,ICA-SVM 方法在选取独立元时,传统的选取方法并没有考虑到样本相关性的影响,因此会对结果有一定的影响。本例中,DW-ICA-SVM 的故障检测率最高,该结果进一步验证了 DW-ICA-SVM 方法的故障检测性能,以及该算法的优越性和有效性。




图 6 非线性数据样本间的自相关性对比图

Fig. 6 Comparison plot of autocorrelation among samples for non-linear data

## 2.2 TE 工业过程

TE,即 Tennessee Esatman(田纳西-伊斯曼过程)工业过程已成为国际上通用的工业过程仿真平台<sup>[26-28]</sup>,被国内外学者广泛用于故障检测和诊断领域。TE 过程包括 5 个主要操作单元、4 种气体进料、2 个气液放热反应生成的 2 种主产品和 2 个衍生放热反应生成的 2 种副产品等,过程工艺复杂,具有较多变量。将 TE 过程产生的数据集用于仿真测试,该数据集是在 TE 仿真器中持续运行 48 h 获得的<sup>[29]</sup>,期间每隔 3 min 进行采样记录。

在 TE 工业过程正常操作条件下选取 200 组正常样本和 200 组故障样本作为训练数据集,测试数据集中包括 160 组故障数据。本例中选取 TE 过程故障 3,7,9,11,17,19,20 和 21 验证本文算法的有效性。以故障 7 为例,对比各种方法的检测性能。本文通过网格搜索方法将惩罚因子  $C$  设置为 0.8,窗宽  $g$  设置为 0.45。ICA 和 ICA-SVM 方法的独立元个数由 85% 累计方差贡献率确定。DW-ICA-SVM 方法利用 DW 准则,选择包含重要隐藏信息的独立元矩阵训练 SVM 模型。根据 DW 值选择的独立元数量会对监控结果产生影响,因此,这里讨论独立元数量的选取方法。通过 DW 准则在信号中查找信噪比,并绘制 DW 色谱图。图 7 是不同变量的 DW 值,选择 DW 值较小的独立元,即在色谱图中颜色较深的独立元,这类独立元被认为比其他独立元更重要。从图 7 可以看出,22 个独立元的颜色较深,这表明它们比其他独立元更重要。对故障 7 的数据集进行不同数量独立元的监控,检测结果如表 2 所示。从表 2 中可以看出,随着选取独立元数量的不同,故障检测率会产生不同幅度的变化。结合色谱图,选择 22 个重要的独立元能够得到最佳的故障检测效果。综上所述,证明了 DW 准则选取重要独立元数量的有效性。




图 7 不同变量的 DW 值


Fig. 7 DW values of different variables

表 2 不同独立元数量的故障检测率


Tab.2 Fault detection rates of different numbers of independent components

独立元数量	18	19	20	21	22	23	24
故障检测率/%	96.88	98.12	98.12	98.12	98.75	97.5	96.88

图 8 是各种算法对故障 7 的检测结果对比图,图中“黑色圆圈”代表故障数据。从图 8 可以清晰地看出 DW-ICA-SVM 的故障检测效果最好,PCA, LPP, ICA, SVM 和 ICA-SVM 的检测效果均低于 DW-ICA-SVM。故障 7 属于阶跃故障类型,ICA 方法能够提取到过程变量中隐藏的非高斯信息,实现对故障特征的有效提取。SVM 方法在训练模型时需要加入正常数据和故障数据一起训练,模型能够学习到故障特征的变化趋势,在测试时快速有效识别正常数据和故障数据并将其分类。本文方法在运用 ICA 获取到隐藏非高斯信息后,又运用 DW 准则进一步处理包含非高斯信息的 IC,筛选出包含更重要信息的 IC,提取到重要的数据特征,并在一定程度上降低了样本间的自相关性,减小了对故障检测的影响。因此,DW-ICA-SVM 方法的故障检测效果最好。



a) PCA  $T^2$ 数据



b) PCA SPE数据



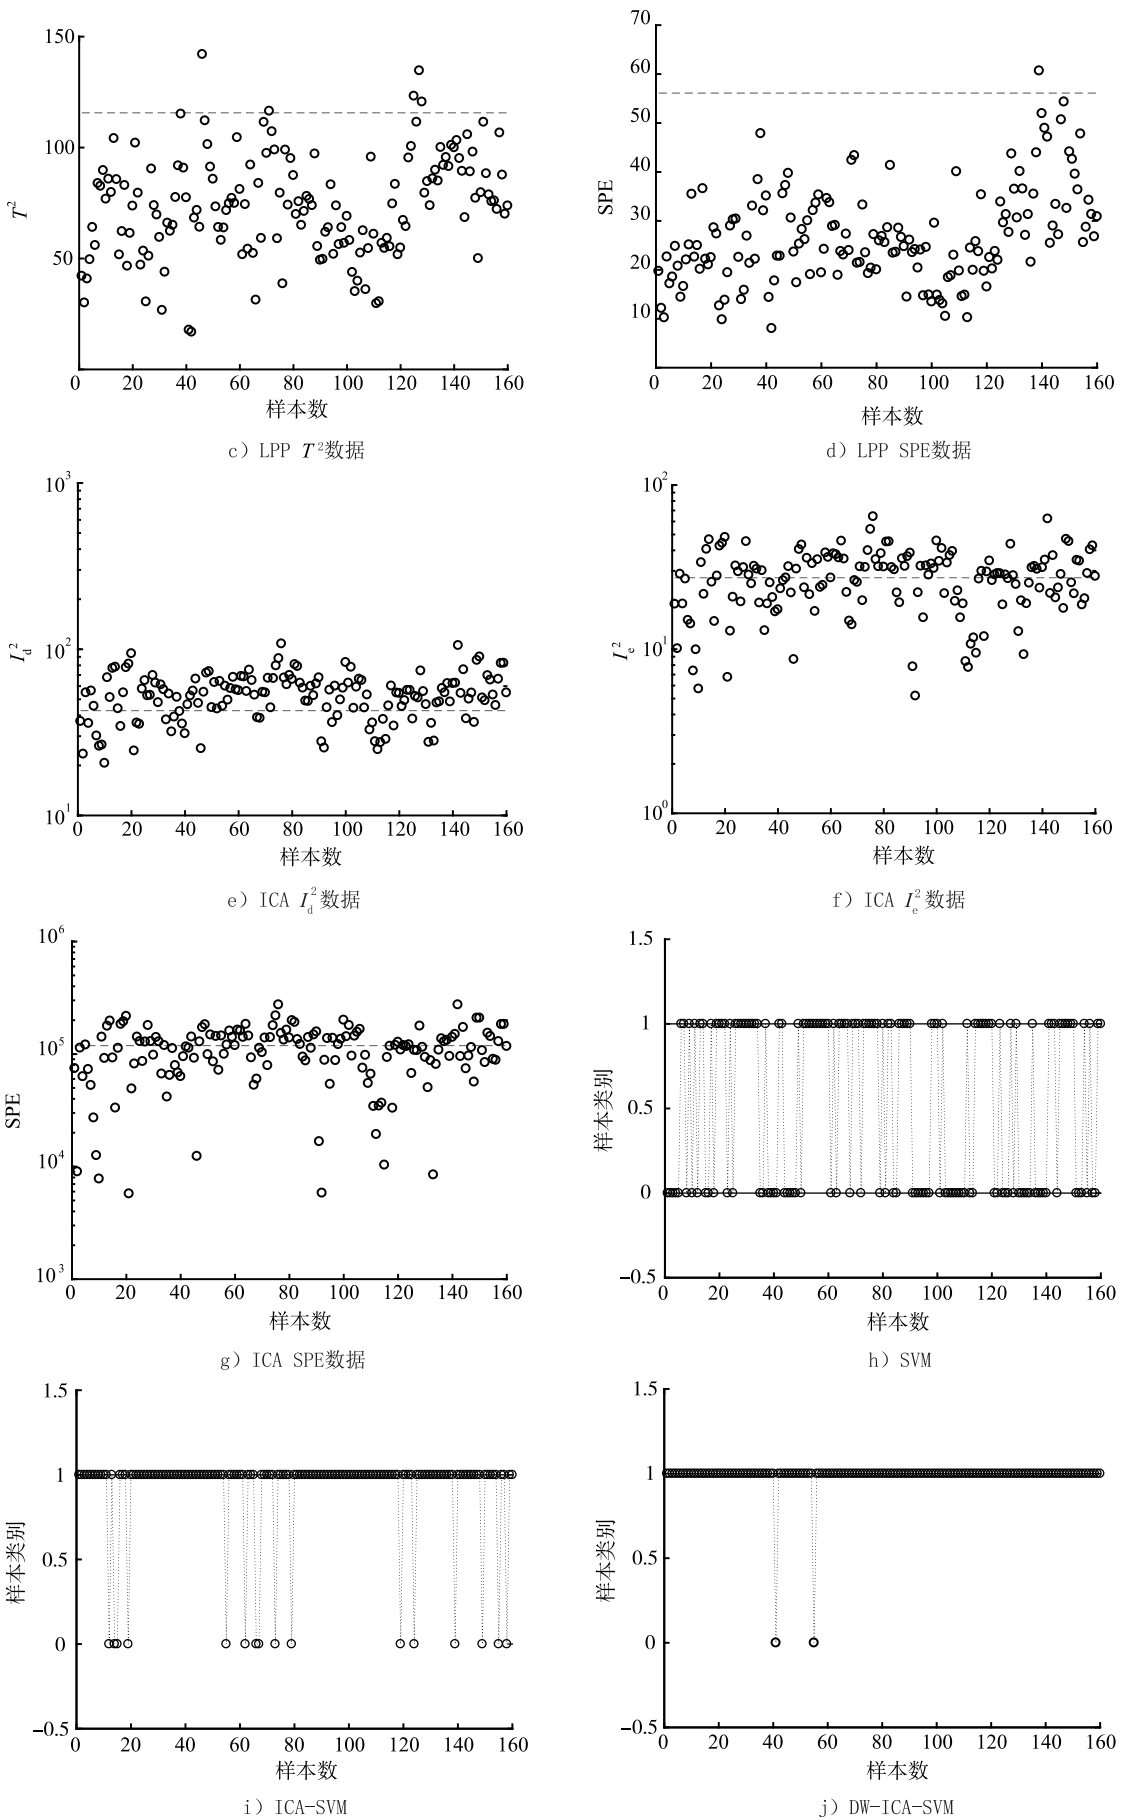


图 8 6 种方法对 TE 工业过程数据的检测结果

Fig. 8 Detection results of six methods for TE data

图9为原始数据和本文方法处理后数据的自相关性对比图。从图9可以看出,原始数据样本间存在较强的自相关性,这会在很大程度上影响故障检测结果,而经过本文方法处理后的样本相关性明显减弱,验证了本文方法的有效性。




图9 TE工业过程数据样本间的自相关性对比图

Fig. 9 Comparison plot of autocorrelation among samples for TE data

本文运用故障检测率来衡量算法的优越性,表3是各种算法对TE过程故障检测率的对比情况。从表3可知,对TE过程的故障3,7,9,11,17,19,20和21进行检测时,与其他检测方法相比较,本文方法的故障检测率都有不同程度的提高,验证了该方法的有效性。

表3 各种算法对TE过程故障检测率对比

Tab.3 Comparisons of fault detection rate of various algorithms on TE process

单位:%

错误类型	PCA		LPP		ICA			SVM	ICA-SVM	DW-ICA-SVM
	$T^2$	SPE	$T^2$	SPE	$I_1^2$	$I_2^2$	SPE			
3	0	38.13	35.63	3.75	6.25	5.00	4.38	66.25	45.00	98.12
7	1.25	68.75	3.13	0.63	76.25	53.13	47.50	53.75	90.00	98.75
9	0.63	43.13	41.25	10.63	12.50	7.50	6.25	76.25	24.37	96.88
11	19.38	82.50	20.62	2.50	30.63	28.75	25.00	63.75	73.12	85.00
17	25.00	95.00	18.12	5.00	80.00	71.88	68.13	81.25	26.87	95.63
19	3.13	75.63	10.00	0.63	15.63	13.13	12.50	89.38	80.00	95.00
20	85.00	83.13	7.50	0	74.38	84.38	65.00	80.00	51.25	96.88
21	75.00	86.25	35.63	7.50	58.13	35.00	10.63	0	56.25	98.12

### 3 结 语

本文提出的基于DW-ICA-SVM的工业过程故障检测方法,运用DW准则计算独立元的DW值,并将DW值升序排列,提取DW值中较小的重要独立元。该方法能够有效提取和识别过程变量中重要的隐藏非高斯信息,降低过程变量间自相关性对故障检测的影响,减小非随机行为,将包含重要IC信息的独立元作为SVM模型的输入,通过样本特征建模获得判别分类函数,实现对故障数据的有效检测,仿真结果验证了该方法的有效性和优越性。

本文主要研究DW-ICA-SVM算法在工业过程故障检测中的实现与仿真实验,但是实际工业过程数据往往具有多模态特性或者动态性,这对检测算法提出了更高的要求,因此,未来需要深入探索这方面的研究,提升算法在多场景中的适应性。

### 参考文献/References:

[1] 周东华,李钢,李元.数据驱动的工业过程故障诊断技术:基于主元分析与偏最小二乘的方法[M].北京:科学出版社,2011.

- [2] 张成,郭青秀,冯立伟,等.基于局部近邻标准化和动态主元分析的故障检测策略[J].计算机应用,2018,38(9):2730-2734.  
ZHANG Cheng, GUO Qingxiu, FENG Liwei, et al. Fault detection strategy based on local neighbor standardization and dynamic principal component analysis[J]. Journal of Computer Applications, 2018, 38(9): 2730-2734.
- [3] LAN T, TONG C D, YU H Z, et al. Nonlinear process monitoring based on decentralized generalized regression neural networks[J]. Expert Systems with Applications, 2020, 150: 113273.
- [4] HUANG J P, YAN X F. Quality-Driven principal component analysis combined with kernel least squares for multivariate statistical process monitoring[J]. IEEE Transactions on Control Systems Technology, 2019, 27(6): 2688-2695.
- [5] 郭金玉,王东琴,李元.基于二阶差商LPP的多模态过程故障检测[J].高校化学工程学报,2020,34(1):182-189.  
GUO Jinyu, WANG Dongqin, LI Yuan. Fault detection of multimode processes based on second order difference quotient LPP[J]. Journal of Chemical Engineering of Chinese Universities, 2020, 34(1): 182-189.
- [6] DU Y C, DU D P. Fault detection and diagnosis using empirical mode decomposition based principal component analysis[J]. Computers & Chemical Engineering, 2018, 115: 1-21.
- [7] SHERIFF ZIYAN M, MANSOURI M, KARIM NAZMUL M, et al. Fault detection using multiscale PCA-based moving window GLRT[J]. Journal of Process Control, 2017, 54: 47-64.
- [8] SHIOKAWA Y, DATE Y, KIKUCHI J. Application of kernel principal component analysis and computational machine learning to exploration of metabolites strongly associated with diet[J]. Scientific Reports, 2018. doi: 10.1038/s41598-018-20121-w.
- [9] 翟坤,杜文霞,吕锋,等.一种改进的动态核主元分析故障检测方法[J].化工学报,2019,70(2):716-722.  
ZHAI Kun, DU Wenxia, LV Feng, et al. Fault detect method based on improved dynamic kernel principal component analysis[J]. CIESC Journal, 2019, 70(2): 716-722.
- [10] SOH W, KIM H, YUM B J. Application of kernel principal component analysis to multi-characteristic parameter design problems[J]. Annals of Operations Research, 2018, 263(1): 69-91.
- [11] HU K L, YUAN J Q. Multivariate statistical process control based on multiway locality preserving projections[J]. Journal of Process Control, 2008, 18(7/8): 797-807.
- [12] 张成,戴繁年,李元.基于DPCA残差互异度的故障检测与诊断方法[J/OL].自动化学报.[2020-03-24].<http://kns.cnki.net/kcms/detail/11.2109.tp.20200323.1459.002.html>.  
ZHANG Cheng, DAI Xunian, LI Yuan. Fault detection and diagnosis based on residual dissimilarity in dynamic principal component analysis[J/OL]. Acta Automatica Sinica. [2020-03-24]. <http://kns.cnki.net/kcms/detail/11.2109.tp.20200323.1459.002.html>.
- [13] KANO M, TANAKA S, HASEBE S, et al. Monitoring Independent components for fault detection[J]. AIChE Journal, 2003, 49(4): 969-976.
- [14] GU Q H, CHANG Y X, LI X H, et al. A novel F-SVM based on FOA for improving SVM performance[J]. Expert Systems with Applications, 2021, 165: 113713.
- [15] ZHAO Y P, HUANG G, HU Q K, et al. An improved weighted one class support vector machine for turboshaft engine fault detection[J]. Engineering Applications of Artificial Intelligence, 2020, 94: 103796.
- [16] EBRAHIMI M A, KHOSHAGHAZA M H, MINAEI S, et al. Vision-based pest detection based on SVM classification method[J]. Computers and Electronics in Agriculture, 2017, 137: 52-58.
- [17] ONEL M, KIESLICH C A, PISTIKOPOULOS E N. A nonlinear support vector machine-based feature selection approach for fault detection and diagnosis: Application to the Tennessee eastman process[J]. AIChE Journal, 2019, 65(3): 992-1005.
- [18] XUE Y T, ZHANG L, WANG B J, et al. Nonlinear feature selection using Gaussian kernel SVM-RFE for fault diagnosis[J]. Applied Intelligence, 2018, 48: 3306-3331.
- [19] JI Z P, ZHANG X J. An integrated fault diagnosis method based on the ICA-SVM[J]. Applied Mechanics and Materials, 2015, 740: 523-526.
- [20] HSU C C, CHEN M C, CHEN L S. Integrating independent component analysis and support vector machine for multivariate process monitoring[J]. Computers & Industrial Engineering, 2010, 59(1): 145-156.
- [21] RUTLEDGE D N, BARROS A S. Durbin-Watson statistic as a morphological estimator of information content[J]. Analytica Chimica Acta, 2002, 454(2): 277-295.
- [22] ZHOU Z, DU N, XU J Y, et al. Randomized kernel principal component analysis for modeling and monitoring of nonlinear industrial processes with massive data[J]. Industrial & Engineering Chemistry Research, 2019, 58(24): 10410-10417.
- [23] MATIOLI L C, SANTOS S R, KLEINA M, et al. A new algorithm for clustering based on kernel density estimation[J]. Journal of Applied Statistics, 2018, 45(2): 347-366.
- [24] LI J S, YAN X F. Process monitoring using principal component analysis and stacked autoencoder for linear and nonlinear coexisting industrial processes[J]. Journal of the Taiwan Institute of Chemical Engineers, 2020, 112: 322-329.
- [25] RATO T J, REIS M S. Advantage of using decorrelated residuals in dynamic principal component analysis for monitoring large-scale systems[J]. Industrial & Engineering Chemistry Research, 2013, 52(38): 13685-13698.
- [26] DOWNS J J, VOGEL E F. A plant-wide industrial process control problem[J]. Computers & Chemical Engineering, 1993, 17(3): 245-255.
- [27] UDUGAMA I A, GERNAEY K V, TAUBE M A, et al. A novel use for an old problem: The Tennessee Eastman challenge process as an activating teaching tool[J]. Education for Chemical Engineers, 2020, 30: 20-31.
- [28] HEO S, LEE J H. Statistical process monitoring of the Tennessee Eastman process using parallel autoassociative neural networks and a large dataset[J]. Processes, 2019. doi: 10.3390/pr7070411.
- [29] JIANG Q C, YAN X F. Non-Gaussian chemical process monitoring with adaptively weighted Independent component analysis and its applications[J]. Journal of Process Control, 2013, 23(9): 1320-1331.