

DOI:10.19651/j.cnki.emt.2314762

# 基于分数阶傅里叶变换与卷积神经网络的 工业过程故障检测\*

李元 辛梦媛

(沈阳化工大学信息工程学院 沈阳 110142)

**摘要:** 基于传统数据驱动的过程故障检测存在忽略正常数据与故障数据之间微小差异和检测不灵敏问题,本文提出了一种基于 FRFT 和 CNN 结合的故障检测方法。从放大正常数据与故障数据之间的微小差异方面入手,一则利用 CVDA 构造残差矩阵用于数据监测,增强灵敏度;二则利用 FRFT 对数据进行变换,将一些幅值低,易被噪声掩盖的故障从时域转换为频域,尽可能放大其特征,使其易检测。最后利用 CNN 对处理完的数据进行检测,解决了忽略微小差异和检测灵敏度低的问题,通过 TE 过程进行实验验证,在故障检测率方面得到提高,表明所提方法的有效性。

**关键词:** 规范残差变量分析;分数阶傅里叶;卷积神经网络;故障检测

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

## Fault detection of industrial processes based on fractional order Fourier transform and convolutional neural network

Li Yuan Xin Mengyuan

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

**Abstract:** Based on the problem of ignoring the slight difference between normal data and fault data and insensitive detection of traditional data-driven process fault detection, this paper proposes a fault detection method based on the combination of FRFT and CNN. Starting from amplifying the small differences between normal data and fault data, a residual matrix is constructed by CVDA for data monitoring to enhance sensitivity. The second is to use FRFT to transform the data, convert some faults with low amplitude and easy to be masked by noise from the time domain to the frequency domain, and amplify their characteristics as much as possible to make them easy to detect. Finally, CNN is used to detect the processed data, which solves the problems of ignoring small differences and low detection sensitivity, and experiments are verified by TE process, which improves the fault detection rate and shows the effectiveness of the proposed method.

**Keywords:** canonical variate dissimilarity analysis; fractional order Fourier transform; convolutional neural networks; fault detection

### 0 引言

故障检测在保证化工过程稳定运行中发挥的重大作用。传统的方法主要有基于模型、专家系统和数据驱动<sup>[1-2]</sup>。其中:基于模型和基于专家的方法需要一定的先验知识;基于数据驱动的方法是利用历史数据搭建好的故障检测模型上实施在线监控,对系统原理及工艺知识的要求相对较低,成为了当今故障检测领域的热门方向<sup>[3-4]</sup>。数据驱动方法主要有统计分析、信号处理和机器学习。统计分

析包括主成分分析(principal component analysis, PCA)、典型变量分析(canonical variate analysis, CVA)和偏最小二乘(partial least squares, PLS)。PCA 是目前常用的多元统计方法<sup>[5]</sup>,也是一种降维方法,通过计算样本的  $T^2$  和 SPE 统计量来检测故障<sup>[6-8]</sup>。PLS 又称隐结构投影,是一种线性降维技术,同样在工业系统故障检测中被广泛应用<sup>[9-10]</sup>,PLS 方法在 PCA 的基础上,考虑了质量变量。传统的基于 PCA 和 PLS 的方法,只使用过程数据的均值和方差信息,它们都属于全局结构信息,因此不能很好地提取

收稿日期:2023-10-13

\* 基金项目:国家自然科学基金(62273242)项目资助

相邻结构的局部特征。并且 PCA 仅使用主元部分忽略了残差部分,容易丢失数据信息。CVA 是在时间序列中提出特征,它的优势在于动态过程监控<sup>[11]</sup>。文献[12]根据故障的时间变化特点,提出了一种基于自适应混合核的 CVA 检测方法。为了充分利用数据残差部分包含的特征,文献[13]提出了一种改进的 CVA 方法,命名为典型变量差异度分析 (canonical variate dissimilarity analysis, CVDA)。CVDA 在 CVA 模型的基础上,构造了差异度特征向量,充分利用残差信息,相比 CVA 方法, CVDA 方法提高了故障检测率<sup>[14]</sup>。

基于信号处理的方法主要有小波分析 (wavelet transform, WT)、谱分析 (spectrum analysis, SA)、经验模式分解 (empirical mode decomposition, EMD), 这些故障诊断方法的核心是对数据进行时频转换,根据转换后的振幅、相位和频率提取特征。进行时频转换时是整体进行映射,容易丢失数据的瞬时特征<sup>[15]</sup>。分数阶傅里叶变换 (fractional order Fourier transform, FRFT) 辟出时域、频域之间新的分数域,将数据变换过程细致分解,可以提取信号映射过程中所有特征。文献[16]应用分数阶傅里叶变换对采集到的故障信号进行预处理和特征提取,有效提取了逆变电路中的故障特征。文献[17]将分数阶傅里叶变换应用于旋转机器故障诊断中,取得了很好的创新成果。目前在分数阶傅里叶变换中,参数的选择对结果有显著影响。分数阶傅里叶阶数确定需要一个合适的方法进行选择,不恰当的参数选择可能导致信号的特征不被正确捕捉或表现出来。单一的故障诊断技术面对复杂工业系统,就会存在精度不高等问题,可以对统计分析、信号处理、人工智能进行多技术融合,文献[18]通过时频分析技术在频域上利用 ANN 实现微小故障的检测和诊断。基于传统数据驱动的过程故障检测存在忽略正常数据与故障数据之间微小差异和检测不灵敏问题,本文提出一种分数阶傅里叶变换与卷积神经网络结合的故障检测方法。首先对数据进行规范变量残差分析,构造新的数据矩阵,然后利用分数阶傅里叶对数据变换,利用互信息来确定 FRFT 的最佳阶数,最后通过卷积神经网络 (convolutional neural networks, CNN) 进行故障检测。CVDA-FRFT-CNN 方法是从放大正常与故障间的差异和提高检测灵敏度方面入手,可以大幅提升工业过程的故障检测率。

## 1 分数阶傅里叶变换与卷积神经网络的基本原理

### 1.1 分数阶傅里叶变换

傅里叶变换 (Fourier transformation, FT) 是一种经典的时频变换手段,广泛应用在信号的时频分析。传统的 Fourier 变换只能将信号在时域和频域之间进行整体变换,无法获得信号的局部时间频率变化特征,分数阶 Fourier 变换开辟出时域、频域之间新的分数域,展示出信号从时域逐步变化到频域的所有变化特征,可以提取信号的局部时频

变化特征。使用分数阶 Fourier 变换将正常数据与故障数据转换到频域上,找到二者差异最大的角度,提取更多的特征。在时频坐标系上将 Fourier 变换看作从时间轴逆时针旋转  $90^\circ$  到频率轴,则分数阶 Fourier 变换算子就是可旋转任意角度的算子,如图 1 所示。

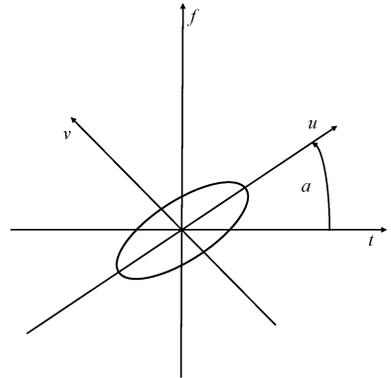


图 1 分数阶 Fourier 变换的时频变换图

输入数据为  $x$ , 其  $p$  阶分数阶 Fourier 变换可表示为  $F^p x$  或者  $X_\varphi(u)$ ,  $X_\varphi(u)$  表示分数阶 Fourier 变换的结果在  $u$  域上,  $\varphi = p\pi/2$  为阶数  $p$  对应的旋转角度,即新变量  $u$  轴相对于时间  $t$  轴逆时针转过的角度。

FRFT 定义为:

$$F^p x = X_\varphi(u) = \int_{-\infty}^{\infty} x(t) K_\varphi(t, u) dt \quad (1)$$

其中,  $K_\varphi(t, u)$  分数阶 Fourier 变换的核函数,定义如下:

$$K_\varphi(t, u) = \begin{cases} A_\varphi \exp(j \frac{t^2 + u^2}{2} \cos\varphi - jut \csc\varphi), & \varphi \neq n\pi \\ \delta(t - u), & \varphi = 2n\pi \\ \delta(t + u), & \varphi = (2n + 1)\pi \end{cases} \quad (2)$$

其中,  $A_\varphi = \sqrt{\frac{1 - j \cos\varphi}{2\pi}}$  为幅度因子。

### 1.2 卷积神经网络

卷积神经网络主要包含:输入层、卷积层、池化层、全连接层及输出层。多个卷积池化模块连接到全连接层,最终在输出层中实现故障标签分类。CNN 学习训练过程分为前向传播和反向传播两种,前者通过每一层计算传播得到网络输出,此过程基于图像输入。反向传播主要涉及到损失函数,通过不断缩小损失函数来调整网络参数同时优化网络。在 CNN 中,输入层为经过 CVDA 和 FRFT 处理后的数据,在卷积层和池化层中分别实现故障特征提取及降低特征维度。

## 2 基于 CVDA-FRFT-CNN 的故障检测模型

CVA 主要是最大化构建的“过去矩阵”与“未来矩阵”之间的相关性,从数据生成状态空间模型, CVA 提供了卓

越的监控功能,并为底层时间相关性提供了更准确的输入-输出描述,CVDA在CVA的基础上,利用过去和未来规范变量之间的差异构造出规范变量残差,通过规范变量残差检测数据变化。

采集数据  $X = [x_1, x_2, \dots, x_i, \dots, x_n]^T \in R^{n \times m}$  作为训练集,其中  $x_i$  表示第  $i$  时刻的采集样本,  $n$  和  $m$  分别表示样本和变量维数,由此构造  $x_i$  对应的历史和未来数据向量  $q_{p,i}, q_{f,i}$ 。

$$q_{p,i} = [x_{i-1}^T, x_{i-2}^T, \dots, x_{i-a}^T]^T \in R^{\hat{n}} \quad (3)$$

$$q_{f,i} = [x_i^T, x_{i+1}^T, \dots, x_{i+a-1}^T]^T \in R^{\hat{n}} \quad (4)$$

其中,  $\hat{n} = m \times a$ , 表示历史和未来数据向量维数;  $a$  表示向量的时间滞后数。进一步构造历史和未来数据矩阵  $Q_p$  和  $Q_f$ , 如式(5)和(6)所示。

$$Q_p = [q_{p,a+1}, q_{p,a+2}, \dots, q_{p,a+N}]^T \in R^{N \times \hat{n}} \quad (5)$$

$$Q_f = [q_{f,a+1}, q_{f,a+2}, \dots, q_{f,a+N}]^T \in R^{N \times \hat{n}} \quad (6)$$

其中,矩阵列对应维数  $N = n - 2a + 1$ 。CVDA算法

通过寻找投影向量  $h \in R^{\hat{n}}$  和  $l \in R^{\hat{n}}$  使得典型变量对  $q_{p,i}, l$  和  $q_{f,i}, h$  具有最大相关性,对应的优化目标定义如式(7)所示。

$$\begin{cases} \max_{l,h} l^T s_{pp} h \\ s.t. l^T s_{pp} l = 1, h^T s_{ff} h = 1 \end{cases} \quad (7)$$

为了实现优化目标采用式(8)中的奇异值分解。

$$S_{pp}^{-1/2} S_{pp} S_{ff}^{-1/2} = U \Lambda V^T \quad (8)$$

式中:  $U$  和  $V$  分别表示左右奇异矩阵;  $\Lambda = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_{\hat{m}})$  是由特征值  $\lambda_i (1 \leq i \leq \hat{m})$  降序排列构成的对角矩阵;  $S_{pp}, S_{ff}$  和  $S_{pf}$  分别表示历史数据协方差阵、未来数据协方差阵、历史与未来数据之间的互协方差阵,其具体表达式如式(9)~(11)所示。

$$S_{pp} = \frac{1}{M-1} Q_p^T Q_p \quad (9)$$

$$S_{ff} = \frac{1}{M-1} Q_f^T Q_f \quad (10)$$

$$S_{pf} = \frac{1}{M-1} Q_p^T Q_f \quad (11)$$

计算式(7)可以得到历史数据和未来数据的投影矩阵  $L = [l_1 l_2 \dots l_{\hat{m}}]$  和  $H = [h_1 h_2 \dots h_{\hat{m}}]$ , 其表达式如式(12)和(13)所示。

$$L = S_{pp}^{-1/2} U \quad (12)$$

$$H = S_{ff}^{-1/2} V \quad (13)$$

典型变量空间由状态子空间和残差子空间组成,特征值  $\lambda_i$  代表投影向量对  $\{l_i, h_i\}$  的相关系数。根据  $\lambda_i$  值的大小,将投影向量对  $\{l_i, h_i\}$  划分入两个子空间,前  $r$  个最大特征值  $\lambda_1 > \lambda_2 > \dots > \lambda_r$  对应的投影向量  $L_r = [l_1, l_2, \dots, l_r]$  确定状态子空间,剩余  $\hat{m} - r$  个特征值对应的投影向量确定残差子空间。求得 CVDA 模型的差异度特征向量,其

对应的计算公式如式(14)所示。

$$d_t = H_r^T q_{f,t} - \Lambda_r L_r^T q_{p,t} \quad (14)$$

基于 CVDA 对数据进行预处理,得到正常数据的差异度特征矩阵  $D_x$  和故障数据的差异度矩阵  $D_y$ , 分别从阶次  $P=0$  开始,以  $P=0.01$  为步长,利用式(1)进行 FRFT 变换,得到  $F^P D_x$  和  $F^P D_y$ , 将 FRFT 与信息熵相结合,利用信息熵来确定 FRFT 的最佳参数。对每一次变换结果求互信息(mutual information, MI)。

$$I(D_x, D_y) = \iint P(D_x, D_y) \log_2 P(D_x, D_y) P(D_x) P(D_y) dD_x dD_y \quad (15)$$

式中:  $P(D_x, D_y)$  为  $(D_x, D_y)$  的联合概率分布;  $P(D_x)$  和  $P(D_y)$  分别为  $D_x, D_y$  的边际分布函数。

将得到  $F^P D_x$  和  $F^P D_y$ , 利用式(15)求  $I(F^P D_x, F^P D_y)$ , 当  $I(F^P D_x, F^P D_y)$  取最小值时,确定此时阶数  $P$  为最佳阶数。在确定的  $P$  对数据利用式(1)进行 FRFT 变换,得到正常变换矩阵  $F^P D_x$ , 和故障数据矩阵  $F^P D_y$ , 以及对应的标签矩阵  $Y_{Dx}$  和  $Y_{Dy}$  作为 CNN 的输入数据,训练 CNN 故障检测模型。核心观点是先将数据 CVDA 变换,然后 FRFT 与信息熵结合,FRFT 是介于时域与频域之间的分数域,在阶次  $P$  对应的  $P$  分数域,正常数据与故障数据的振幅、频率都不相同,结合信息熵来确定正常数据与故障数据差异最大的分数域,在这个基础上对数据分类看其训练结果,并将该模型作为在线监测的分类模型。

故障检测可以分为离线建模和在线监测离线建模。离线建模的步骤如下:

步骤 1) 采集历史数据,按照方差和均值对数据标准化。

步骤 2) 对预处理完的数据进行 CVDA,窗口步长选择 5,求得差异度特征矩阵。

步骤 3) 对差异度特征矩阵按阶次递增进行 FRFT 变换,得到变换矩阵  $f_p$ 。

步骤 4) 对变化矩阵  $f_p$  求互信息,确定最佳阶数  $P$ 。

步骤 5) 处理好的数据作为 CNN 输入,训练 CNN 故障检测模型。保存训练模型中所获得的参数以及最佳阶次  $P$ 。

在线检测。在线检测的步骤如下:

步骤 1) 采集  $i$  时刻的数据,对数据进行标准化处理。

步骤 2) 利用 CVDA 将新数据进行处理,得到差异度特征矩阵  $D$ 。

步骤 3) 使用离线建模确定的阶数  $P$ ,对  $D$  进行傅里叶变换。得到变换矩阵  $f_p$ 。

步骤 4) 将变换矩阵作为输入数据,导入训练好的 CNN 故障检测模型。

步骤 5) CNN 输出检测结果,判断  $i$  时刻数据是否发生故障。

CVDA-FRFT-CNN 故障检测步骤如图 2 所示。

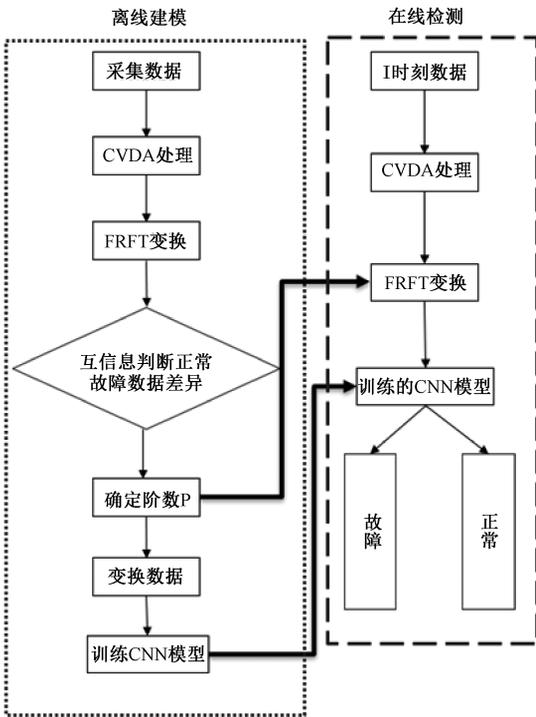


图 2 故障检测流程图

### 3 TE 化工过程

TE 过程仿真应用平台是一个基于实际工业过程的仿真例子,用于测试过程系统工程中故障检测和诊断方法的效率<sup>[19]</sup>。Tennessee Eastman 过程最早由 Downs 和 Vogel 提出,其原型是美国伊斯曼化学公司的一个真实工业过程。主要由反应器、冷凝器、循环压缩机、气液分离器以及汽提塔这 5 个部分组成。该过程涉及 8 种物料,分别为主要参加反应的气体进料 U、C、D、E;惰性不可溶进料 B;反应副产品 F 以及反应液态主产物 G 和 H。TE 过程包括 12 个操作变量和 41 个监控变量,其中,41 个监控变量又可以划分为 22 个过程测量变量以及 19 个成分测量变量,为了模仿真实的工业生产环境,引入了 21 种故障,具体的故障描述如表 1 所示。

为了验证本文方法的有效性,分别做了基于 CNN 和基于 FRFT-CNN 方法以及本文方法关于 TE 过程的 21 种故障检测实验。基于 CNN 的方法 1 没有使用 FRFT 和 CVDA 处理数据,直接使用 CNN 进行数据训练;基于 FRFT-CNN 的方法 2 使用互信息确定 FRFT 的最佳阶数,变换矩阵作为输入数据进行 CNN 故障检测模型训练;本文所提方法 3 未直接使用原始数据进行 FRFT 变换,使用 CVDA 构造差异度特征矩阵 D,MI 确定 FRFT 变换的最佳阶数,变换矩阵导入 CNN 故障检测模型进行训练,

根据 3 种方法检测准确度以及检测难易程度,故障可分为 3 类。故障 1、2、6、8、12、13、16 和 18 构成第一类。这些故障很明显,几种方法都可以轻松检测检测结果如表 2 所示。

表 1 TE 过程的 21 种故障

故障编号	性质描述	变化类型
IVD1	物料 U/C 进料比改变,物料 B 含量不变	阶跃
IVD2	物料 U/C 进料比改变,物料 B 含量改变	阶跃
IVD3	物料 D 进料温度改变	阶跃
IVD4	反应器冷却入口温度改变	阶跃
IVD5	冷凝器冷却入口温度改变	阶跃
IVD6	物料 U 进料损失	阶跃
IVD7	物料 C 压力损失	阶跃
IVD8	物料 U、B、C 的组成比例改变	随机变量
IVD9	物料 D 进料温度改变	随机变量
IVD10	物料 C 进料温度改变	随机变量
IVD11	反应器冷却水入口温度改变	随机变量
IVD12	冷凝器冷却水入口温度改变	随机变量
IVD13	反应动力学参数改变	慢偏移
IVD14	反应器冷却阀门	粘住
IVD15	冷凝器冷却阀门	粘住
IVD16	未知	未知
IVD17	未知	未知
IVD18	未知	未知
IVD19	未知	未知
IVD20	未知	未知
IVD21	物流 4 阀门固定在恒定位置	恒定位置

表 2 故障第一类 3 种方法检测率

故障序号	CNN/ %	FRFT-CNN/ %	CVDA-FRFT-CNN/ %
1	81.28	99.50	99.50
2	96.61	95.50	99.50
6	98.00	99.38	99.50
8	88.88	97.00	97.36
12	93.37	99.12	99.75
13	89.88	94.37	95.98
16	83.25	88.00	98.48
18	84.38	87.38	89.32

对于故障 18,3 种方法检测率都很高,相比而言, CVDA-FRFT-CNN 在检测率高一点,基于 CNN 的方法,如图 3(a)所示,在正常样本 0~160 中,仍有几个误判为故障,样本 160~310 没有检测出故障,基于 FRFT-CNN 的方法中,如图 3(b)所示,在正常样本 1~160 中没有误判为故障的,基于 CVDA-FRFT-CNN 的方法中,如图 3(c)所示,同样正常样本 1~160 中没有误判为故障的,检测率比另外两种方法高一点。其中 FRFT 主要是为了找到正常数据与故障数据最大差异角度,采用 CVDA 构造差异度特征矩阵主要是为了提高检测灵敏度,而第一类故障,故障与正常

差异较大,因此 FRFT 和 CVDA 作用不明显。

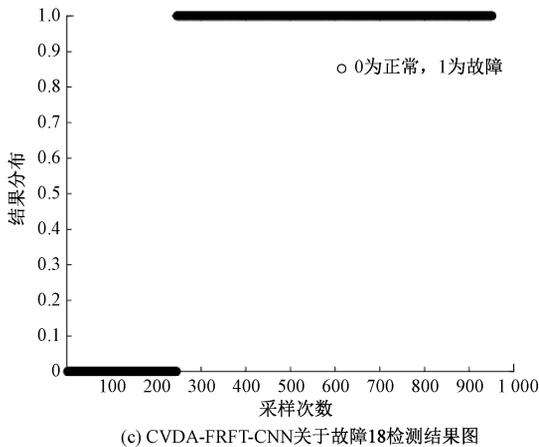
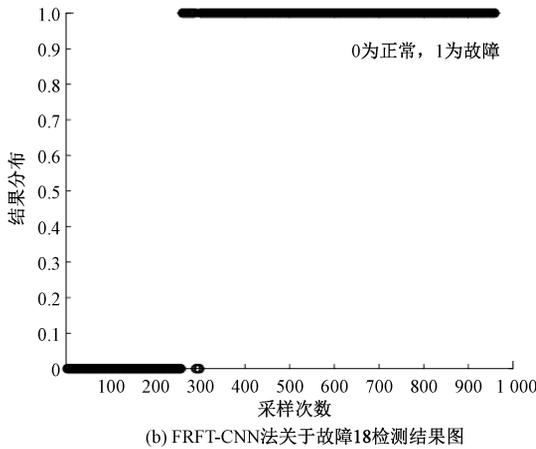
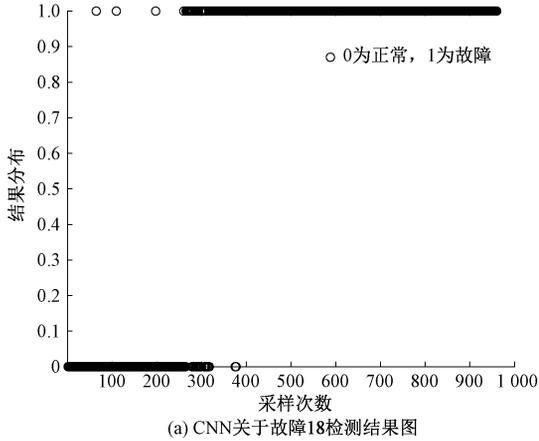


图3 3种方法关于故障18检测结果图

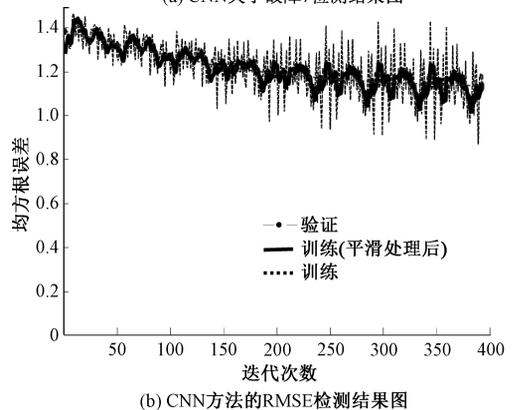
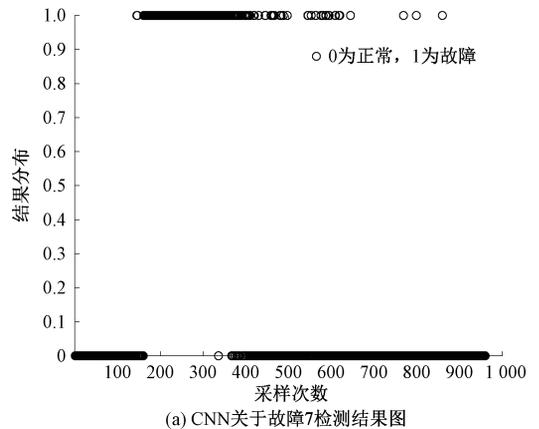
故障4、5、7、10、11、14、17、19和20构成第2类,这类故障基于CNN方法检测率不高,在加入FRFT和CVDA对数据处理后,检测率大幅提升,同时误报率降低。检测结果如表3所示。

数据未处理直接使用CNN训练测试效果不好,加入FRFT检测效果有明显提升,如故障4、7、14、17,其中故障7,

表3 故障第二类3种方法检测率

故障序号	CNN/ %	FRFT-CNN/ %	CVDA-FRFT-CNN/ %
4	43.25	95.87	99.87
5	44.50	57.37	99.75
7	43.63	100	100
10	67.37	77.88	95.60
11	65.12	85.12	96.48
14	54.87	99.88	99.87
17	63.38	90.75	96.86
19	58.50	77.12	98.99
20	59.13	77.12	94.47

CNN单独检测,如图4(a)所示,检测率只有43.63%,在采样次数为400~960基本上没有检测出故障。如图4(b)所示,迭代400次,均方根误差(root mean square error, RMSE)最终稳点在1.2,如图4(c)所示,损失函数稳定在0.8。加入FRFT处理数据后,如图4(d)所示,CNN故障检测模型检测率为100%,如图4(e)所示,迭代500次,MSE稳定在0.2,损失函数为0.1,如图4(f)所示,后者在检测率、MSE等各个方面都比前者效果要好。这类数据故障为第二种类型,正常数据与故障数据差异较小,因此采用FRFT先找到二者差异最大的角度,其中MSE是CNN的预测结果与实际结果的差值,未加FRFT的数据在进行



故障 5、10、19 和 20, FRFT-CNN 检测率均值在 70%, 检测率较低, 加入 CVDA 构造差异度特征矩阵, 在进行 FRFT 数据变换, CNN 检测, 检测大幅提高。故障 5 是温度发生变化形成的一种阶跃故障, 由图 5(a) 和 (d) 可知, 基于 FRFT-CNN 和基于 CVDA-FRFT-CNN 两种方法成功地检测了样本 160~400 的故障, 而在样本 400 之后基于 FRFT-CNN 方法只能检测到小部分故障, 基于 CVDA-FRFT-CNN 的方法检测到样本 160 至过程结束的大部分故障, 1~160 正常数据检测结果中, 基于 FRFT-CNN 方法有误判, 基于 CVDA-FRFT-CNN 方法没有误判, 比较得出基于 CVDA-FRFT-CNN 方法具有较高的检测率和较低的误报率。其中基于 FRFR-CNN 方法的均方根误差和损失函数均比基于 CVDA-FRFT-CNN 方法要高很多。如图 5(b)、(c)、(e)、(f) 所示。

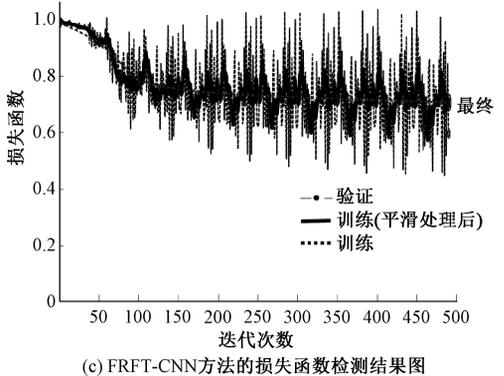
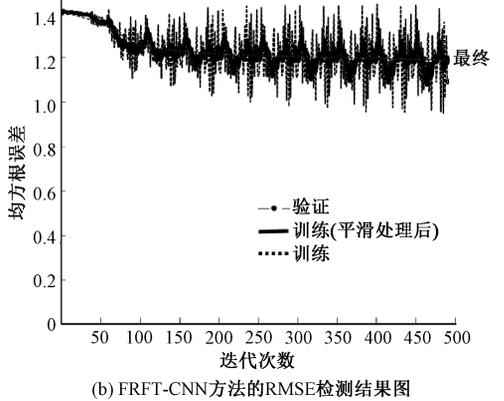
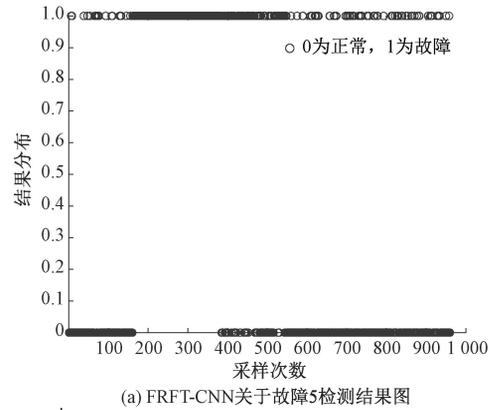
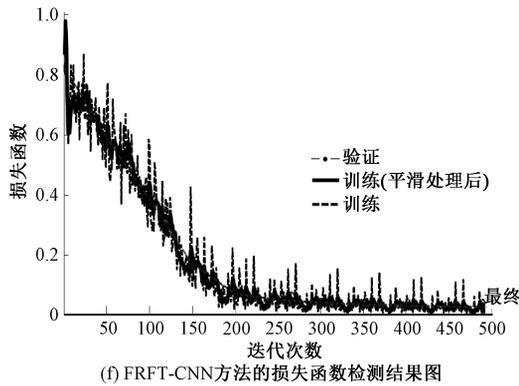
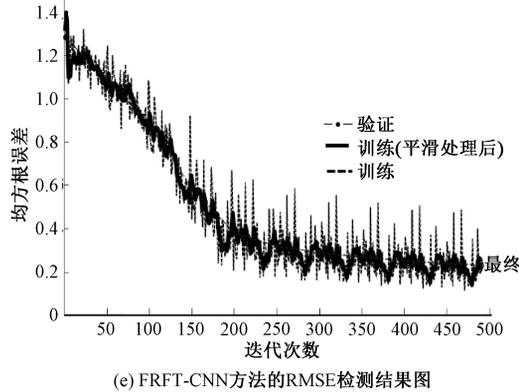
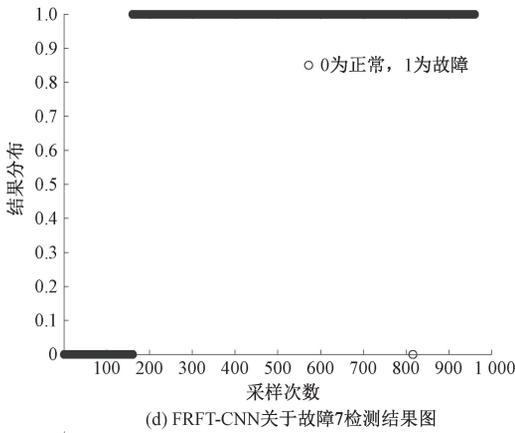
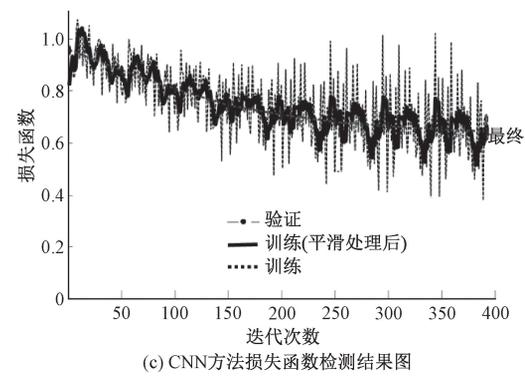
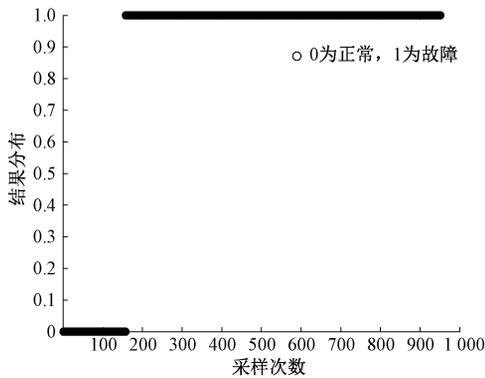
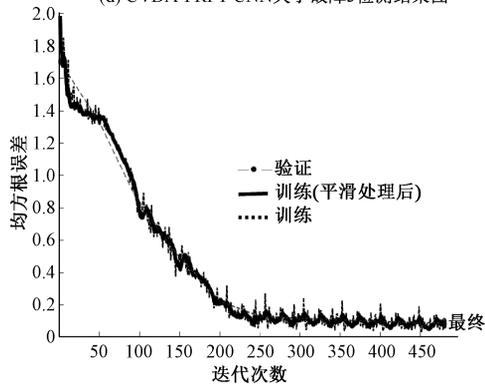


图 4 CNN 与 FRFT-CNN2 种方法关于故障 7 检测结果图

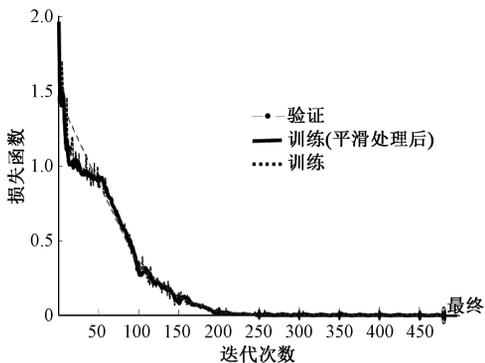
CNN 模型训练时, RMSE 和损失函数都比较大, 训练结果不好, CNN 不能准确的对数据进行分类。



(d) CVDA-FRFT-CNN关于故障5检测结果图



(e) CVDA-FRFT-CNN方法的RMSE检测结果图



(f) CVDA-FRFT-CNN方法的损失函数检测结果图

图5 FRFT-CNN和CVDA-FRFT-CNN关于故障5结果图

故障3、9、15和21构成实验最后一个类别。这些故障对系统的影响很小,并且很难进行检测。基于CNN的方法检测率低,基于FRFT-CNN和基于CVDA-FRFT-CNN的方法虽然检测率高,同样误报率也高,可以认为对这几个故障的检测效果不好,其中故障3、9和15是微小故障,幅值低,易被噪声扰动和掩盖,这3种方法不能对其有效检测。如表4所示。

故障3、9、15和21构成实验最后一个类别。这些故障对系统的影响很小,并且很难进行检测。基于CNN的方法检测率低,基于FRFT-CNN和基于CVDA-FRFT-CNN的方法虽然检测率高,同样误报率也高,可以认为对这几个故障的检测效果不好,其中故障3、9和15是微小故障,这几种方法不能对其有效检测。

表4 故障第三类3种方法检测率

故障序号	CNN/ %	FRFT-CNN/ %	CVDA-FRFT-CNN/ %
3	45.75	81.13	90.83
9	58.87	86.00	89.07
15	66.75	72.50	91.33
21	14.50	72.88	95.73

如上所示,本文提出的方法除对故障3、9、15和21以外,均能有效检测,故障样本的检测率显著提高。

## 4 结论

本文提出的CVDA-FRFT-CNN,从放大正常工况下和故障工况下的数据差异入手,CVDA是基于残差指标构建差异度特征矩阵,可以提高检测的灵敏度,FRFT是将数据从时域转化为频域,通过阶数的改变,不断改变数据转化的频域角度,相比传统的傅里叶变换可以获取信号的局部时频变化特征。在提高检测灵敏度和放大正常与故障差异的基础上,使用CNN进行数据分类,通过一次一次的迭代,特征提取得足够完备,可以找到最贴合的函数,从而检测出故障。

该方法仍不能很好的检测微小故障,这也是下一步研究的目标。

## 参考文献

- [1] 宫文峰,陈辉,张美玲,等. 基于深度学习的电机轴承微小故障智能诊断方法[J]. 仪器仪表学报,2020,41(1): 195-205.
- [2] 李元,张昊展,唐晓初. 基于多模态数据全信息的概率主成分分析故障检测研究[J]. 仪器仪表学报,2021, 42(2):75-85.
- [3] GE Z. Review on data-driven modeling and monitoring for plantwide industrial processes [J]. Chemometrics and Intelligent Laboratory Systems,2017,171:16-25.
- [4] GE Z, SONG Z, GAO F. Review of recent research on data-based process monitoring [J]. Industrial & Engineering Chemistry Research, 2013, 52 (10): 3543-3562.
- [5] ASGHAR F, TALHA M, KIM S Y, et al. Hotelling T<sup>2</sup> index based PCA method for fault detection in transient state processes [J]. Journal of Institute of Control, Robotics and Systems,2016,22(4):276-280.
- [6] NAYAK D R, DASH R, MAJHI B. An improved pathological brain detection system based on two dimensional PCA and evolutionary extreme learning machine[J]. Journal of Medical Systems,2018,42(1): 1-15.
- [7] 邱天,白晓静,郑茜予,等. 多元指数加权移动平均主元

- 分析的微小故障检测[J]. 控制理论与应用, 2014, 31(1):19-26.
- [8] 谢彦红, 杨滕, 贾冬妮, 等. 基于主元分析的滑动窗口累积和的微小故障检测[J]. 计算机应用与软件, 2023, 40(5):60-66, 96.
- [9] TONG C D, LAN T, YU H Z, et al. Distributed partial least squares based residual generation for statistical process monitoring[J]. Journal of Process Control, 2019, 75:77-85.
- [10] JIA Q L, ZHANG Y W. Quality-related fault detection approach based on dynamic kernel partial least squares[J]. Chemical Engineering Research and Design, 2016, 106:242-252.
- [11] CHEN Z W, YANG C H, PENG T, et al. A cumulative canonical correlation analysis-based sensor precision degradation detection method [J]. IEEE Transactions on Industrial Electronics, 2019, 66(8): 6321-6330.
- [12] 姚林, 张岩. 基于自适应混合核典型变量分析的工业过程质量相关故障检测[J]. 控制与决策, 2021, 36(4): 801-807.
- [13] PILARIO K E S, CAO Y. Canonical variate dissimilarity analysis for process incipient fault detection [J]. IEEE Transactions on Industrial Informatics, 2018, 14(12):5308-5315.
- [14] 杨明辉, 刘晓月, 邓晓刚, 等. 基于加权概率 CVDA 的动态化工系统微小故障检测[J]. 化工学报, 2022, 73(9):3963-3972.
- [15] 文成林, 吕菲亚, 包哲静, 等. 基于数据驱动的微小故障诊断方法综述[J]. 自动化学报, 2016, 42(9):1285-1299.
- [16] 吴鑫. 基于分数阶傅里叶变换与模式识别的逆变电路开路故障诊断[D]. 南京:南京航空航天大学, 2013.
- [17] 张鹏. 基于分数阶时频分析的机械故障诊断方法研究[D]. 南昌:南昌航空大学, 2017.
- [18] BHOWMIK P S, PRADHAN S, PRAKASH M, et al. Investigation of wavelets and radial basis function neural network for incipient fault diagnosis in induction motors[C]. 2013 International Conference on Circuits, Controls and Communications (CCUBE), Bengaluru, India, 2013: 1-5.
- [19] 李元, 姚宗禹. 基于邻域保持嵌入的主多项式非线性过程故障检测[J]. 上海交通大学学报, 2021, 55(8): 1001-1008.

#### 作者简介

李元, 教授, 博士生导师, 主要研究方向为基于数据驱动技术的复杂过程故障检测与诊断。

E-mail: li-yuan@mail.tsinghua.edu.cn

辛梦媛, 硕士研究生, 主要研究方向为基于数据驱动的过程故障监控与诊断研究。

E-mail: 2933154758@qq.com