

改进弗雷歇距离的 AROMF 及在流程工业故障诊断应用

雷海, 曹健[†], 李擎

(北京信息科技大学 自动化学院, 北京 100192; 北京信息科技大学 现代测控技术教育部重点实验室, 北京 100192)

摘要: 针对复杂的动态流程工业过程中故障模式匹配因曲线长度或参数化差异导致的匹配难题, 本文提出了一种新颖的基于弗雷歇距离的自适应秩序形态滤波器集成局部保留投影的故障诊断方法。首先, 在本文所提出的基于弗雷歇距离的自适应秩序形态滤波器集成局部保留投影(LPP-FAROMF)方法中, 保留数据局部流形信息的局部保留投影(LPP)算法, 用来提取出与故障相关的特征信息, 解决了数据的高维和非线性问题, 进而得到所需的模板信号和测试信号; 其次, 将弗雷歇距离引入自适应秩序形态滤波器(AROMF)的距离误差中, 用来对测试信号进行基于弗雷歇距离的自适应秩序形态滤波器(FAROMF)变换得到输出趋势特征, 该方法降低了对曲线长度和参数化的一致性要求, 而且可以综合考虑空间相似性和动态特征, 因此计算输出趋势与模板趋势之间的误差更加准确且合理; 最后, 田纳西-伊士曼过程被用来验证所提出方法的性能。结果表明, (LPP-FAROMF)在故障诊断中表现出更高的准确度、鲁棒性和速度。

关键词: 故障诊断; 弗雷歇距离; 局部保留投影; 田纳西-伊士曼过程

引用格式: 雷海, 曹健, 李擎. 改进弗雷歇距离的 AROMF 及在流程工业故障诊断应用. 控制理论与应用, 2026, 43(4): 832–842

DOI: 10.7641/CTA.2024.40291

Improved Fréchet distance based AROMF and its application in process industry fault diagnosis

LEI Hai, CAO Jian[†], LI Qing

(School of Automation, Beijing Information Science and Technology University, Beijing 100192, China;
Key Laboratory of Modern Measurement & Control Technology, Ministry of Education,
Beijing Information Science and Technology University, Beijing 100192, China)

Abstract: Addressing the challenge of fault pattern matching in complex dynamic process industries due to variations in curve length or parameterization, this paper presents a novel Fréchet distance-based adaptive rank-order morphological filter (FAROMF) integrated with locality preserving projections (LPP) for fault diagnosis. Firstly, in the proposed method, the LPP algorithm preserves the local streaming information of the data is used to extract the fault-related features, the high dimensionality and nonlinearity of the data can be overcome to obtain the required template signals and test signals. Secondly, the Fréchet distance which is introduced into the distance error of AROMF is used to obtain the output trend characteristics from the FAROMF transform of the test signal, which reduces the consistency requirements of curve length and parameterization, considers the spatial similarity and dynamic characteristics, so the error between the output trend and the template trend is calculated more accurately and reasonably. Finally, Tennessee Eastman process (TEP) is used to validate the performance of the proposed method. The results show that LPP-FAROMF exhibits higher accuracy, robustness and speed in fault diagnosis.

Key words: fault diagnosis; Fréchet distance; locality preserving projections; Tennessee Eastman process

Citation: LEI Hai, CAO Jian, LI Qing. Improved Fréchet distance based AROMF and its application in process industry fault diagnosis. *Control Theory & Applications*, 2026, 43(4): 832–842

1 引言

故障诊断已经在现代流程工业工厂中广泛应用, 但其相关技术的发展成为现代流程工业中提高生产

力和安全生产的关键问题之一^[1]. 相关的科研研究人员在故障的快速检测和诊断问题上做了大量的研究, 并介绍了许多有关故障诊断的方法^[2]. 一般来说, 故

收稿日期: 2024-05-22; 录用日期: 2024-11-12.

[†]通信作者. E-mail: caojian@bistu.edu.cn; Tel.: +86 15810006081.

本文责任编辑: 阳春华.

北京信息科技大学校科研项目(2023XJJ10)资助.

Supported by the Research Foundation of Beijing Information Science and Technology University (2023XJJ10).

障诊断的方法主要有3种:基于数据驱动的故障诊断方法、基于解析模型的故障诊断方法和基于知识定性分析的故障诊断方法^[3-4]。由于过程故障的多样性以及故障数据的高度耦合性,复杂工业过程的故障诊断往往难以达到高准确率^[5]。相比于解析模型和定性分析,数据驱动仅需对历史数据处理便可实现诊断任务,人们正在把重心放在基于数据驱动的故障诊断领域上^[6]。

数据驱动的方法主要是以多元统计分析为代表,一般来说可以将多元统计方法分为两大类:一类是线性的方法,另一类是非线性方法^[7]。常见的线性多元统计方法主要有主成分分析方法(principal component analysis, PCA)^[8]、费舍尔判别分析方法(Fisher discriminant analysis, FDA)^[9]、偏最小二乘(partial least squares regression, PLS)^[10]等方法。然而,从复杂流程工业过程中得到的数据大多数呈现出高维度、强耦合和非线性的特征^[11],这些方法在处理数据的特征问题上显得不尽人意。所提出的流形学习方法可以有效地解决非线性问题。局部保留投影(locality preserving projections, LPP)方法通过寻找目标序列的线性映射,降低原始数据的维度,不仅可以保留数据的局部空间特征,还可以解决新数据不能直接得到新映射的问题,具有简单、有效、泛化能力强等优点^[12]。

在故障的分类问题上,LPP算法只是对数据的处理上有良好的作用,然而,对于分类任务而言,LPP提取的特征在普通的分类器中获得的准确性却相对较低。自适应秩序形态滤波器(adaptive rank-order morphological filter, AROMF)是一种基于数学形态学的信号处理方法^[13]。在AROMF的算法中,它可以通过计算模板信号与输出趋势的迭代误差距离来进行模式相似性匹配,能够准确地分类故障模式。然而,在传统的AROMF模式匹配方法中,一般采用欧氏距离作为两个信号相似性匹配的迭代误差距离,要实现这两个信号的匹配,需要达到比较严格的条件,要求两个信号具有相同信号长度且特征点要一一对应,如果信号不满足条件,两个信号在匹配时就会出现误差距离的偏差,影响匹配精度,同时计算量复杂度高,影响模式识别速度。

为了解决模式匹配中因曲线长度或参数化差异导致的匹配难题,本文提出了基于弗雷歇距离的自适应顺序形态滤波器(Fréchet distance-based AROMF, FAROMF)。该方法不仅降低了对曲线长度和参数化的一致性要求,而且充分考虑了曲线上点的顺序以及匹配过程中曲线的形状变化。通过计算两个序列上两点之间的弗雷歇距离,FAROMF能有效提升相似测试信号与监督信号之间的匹配度,从而在处理复杂形状变化的曲线时展现出显著优势。这一方法的引入,大大提升了模式匹配的速度和准确性,尤其在数据降维后的应用中表现更为突出。

为了进一步拓展FAROMF的应用领域并提升其实用性,本文将弗雷歇距离度量方式与AROMF相结合,创新性地提出了一种FAROMF集成LPP的故障诊断方法。首先,针对数据的非线性和高维性,利用LPP算法提取原始数据的关键特征,生成故障测试信号和模板信号。随后,FAROMF对这两类信号进行形态变换,并依据不同模板信号的监督产生各异的弗雷歇距离,进而筛选出与测试信号相似度最高的模板信号。最后,通过田纳西-伊士曼过程(Tennessee Eastman process, TEP)的案例研究验证了LPP-FAROMF方法的有效性。仿真结果表明,这一方法不仅显著提升了故障诊断的速度,还有效降低了故障的误报率,为故障诊断领域提供了新的有力工具。本文的主要贡献如下:

1) 传统AROMF算法使用欧氏距离计算信号之间的误差,本文创新性地引入了弗雷歇距离到AROMF中,弗雷歇距离更能反映曲线形状和顺序变化的相似性,解决了信号长度和特征点对齐的严格要求问题;

2) 本文首次将FAROMF与LPP算法相结合,实现故障诊断任务,并在TEP过程验证了该方法的故障诊断准确度和鲁棒性。

本文的其余组织如下:在第2节中,回顾了与本文相关的算法与理论;在第3节中,使用TEP来验证LPP-FAROMF的有效性;最后,第4部分对本文进行了总结,并讨论了未来可能的工作。

2 基于LPP-FAROMF的相关算法

2.1 LPP算法

LPP算法在数据处理流程上与PCA具有相似之处,然而,两者在处理数据的方式上存在显著区别。LPP算法不仅关注数据的整体分布,还特别强调了样本点之间的相对位置关系。这种对样本点间相对位置关系的重视,使得LPP能够更精准地捕捉到数据中与故障模式密切相关的关键特征,通过考虑数据的局部特性,LPP在数据降维的过程中能够保留更多的局部结构信息,这对于后续的故障识别和分析至关重要。因此,相较于PCA,LPP在故障诊断领域展现出更强的适用性和准确性。在本文的研究中,由于原始数据的复杂性,首先对其进行降噪和归一化处理,处理后的数据集表示为 $X = \{x_1, x_2, \dots, x_n\} \in \mathbb{R}^{m \times n}$,然后利用KNN算法找到通过处理后的 X 每个节点的 k 个邻近点,计算该点与邻近点的欧氏距离,如果两点之间的距离较小,则通过热核函数来赋予这两点较高的权值,相反则赋予较低的权值。权值矩阵可以通过热核函数来计算,如式(1)所示:

$$W_{ij} = \begin{cases} \exp\left(-\frac{\|x_i - x_j\|^2}{t}\right), & x_i \text{ 和 } x_j \text{ 是近邻点,} \\ 0, & \text{其他情况,} \end{cases} \quad (1)$$

其中 t 为热核函数的参数, $t > 0$ 。将高维空间的数据向低维空间 $F \in \mathbb{R}^{\nu \times n}$ ($\nu < m$)进行映射可以得到数据

集 Y , 即 $Y = A^T X$. 为了使映射后的点距离最小, 得到如下优化函数:

$$\min J = \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \|y_i - y_j\|^2 W_{ij}. \quad (2)$$

为了方便计算对式(2)进行简化改写, 如下所示:

$$\begin{aligned} \min J = \arg \min & \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \|y_i - y_j\|^2 W_{ij} = \\ & \arg \min (\sum_i A^T x_i D_{ii} x_i^T A - \\ & \sum_{ij} A^T x_i W_{ij} x_j^T A) = \\ & \arg \min (A^T X D X^T A - A^T X W X^T A) = \\ & \arg \min \operatorname{tr}(A^T X L X^T A), \end{aligned} \quad (3)$$

其中 $D_{ii} = \sum_{j=1}^n W_{ij}$, 矩阵 $L = D - W$ 是基尔霍夫矩阵. 为了不让目标函数出现0解的情况, 对其加入约束条件 $Y^T D Y = 1$. 通过引入拉格朗日函数, 将上述目标函数简化为式(4), 即

$$X L X^T A = \lambda X D X^T A. \quad (4)$$

通过对上式的求解, 可以得到广义特征值 λ_i , 计算出 ν 个最小非零特征值及其对应的特征向量, 特征向量就组成了所需要的投影矩阵 A , 再将处理后的数据与矩阵 A 相乘, 就得到降维后的数据集 Y .

2.2 FAROMF算法

AROMF 是对于秩序形态滤波器 (rank-order morphological filter, ROMF) 上的发展和改进^[14]. 对于将欧氏距离作为信号间误差迭代距离的传统AROMF, 由于故障的时间和规模差异性, 采用传统AROMF模型在故障检测和诊断过程中面临时间差异性的问题, 这可能导致很难达到欧氏距离的计算条件, 进而对于同一类型故障的准确识别变得复杂.

为解决这一限制, 本文引入弗雷歇距离至自适应顺序形态滤波器, 创新性地构建了FAROMF. 在曲线相似度匹配方面, 弗雷歇距离无需要求两曲线在长度或参数化上完全一致, 同时考虑了曲线上点的顺序以及匹配过程中曲线的形状变化. 该方法能够处理曲线之间的形状变化, 从而有效解决了欧氏距离存在的问题.

当FAROMF用于模式匹配时, 如果数据的维度太高, 那么就会影响匹配性能. 所以, 首先利用LPP算法来降低训练数据的维度, 得到所需的模板信号 $d_i = \{d_i^1, d_i^2, \dots, d_i^n\} F \in \mathbb{R}^{\nu \times n}$, 将其作为监督信号. 同时对单个不同故障模式的测试数据也进行高维空间向低维空间的映射, 得到降维后的测试信号 $p = \{p^1, p^2, \dots, p^n\} F \in \mathbb{R}^{\nu \times n}$. 将测试信号作为输入, 不同模板信号作为监督信号, 让测试信号在不同模板信号的监

督下进行FAROMF形态变换, 得到输出信号 $y = \{y^1, y^2, \dots, y^n\} F \in \mathbb{R}^{\nu \times n}$. 变换过程表示为 $y_i^n = F(p, d_i^n)$.

离散弗雷歇距离应用于两条曲线相似度匹配时, 对于每一个模板信号和输出信号的每一维度分别可以表示为

$$\sigma_j(d) = \{u_1, u_2, \dots, u_n\}, \quad (5)$$

$$\sigma_j(y) = \{w_1, w_2, \dots, w_n\}, \quad (6)$$

其中 $j = 1, 2, \dots, \nu$, 使用 $\sigma_j(d)$ 和 $\sigma_j(y)$ 分别表示两曲线离散点的顺序集合, 则通过对比二者可生成如式(7)所示的序列点对:

$$L = \{(u_{a_1}, w_{b_1}), (u_{a_2}, w_{b_2}), \dots, (u_{a_n}, w_{b_n})\}, \quad (7)$$

在上述式子中: $a_1 = 1, b_1 = 1, a_n = n, b_n = n$, 对于任意 $i = 1, 2, \dots, n$ 有 $a_{i+1} = a_i$ 或 $a_{i+1} = a_i + 1$ 和 $b_{i+1} = b_i$. d, y 轨迹点之间的序列对之间长度 $\|L\|$ 定义为各序列对中欧式距离最大的值, 如式(8)所示:

$$\|L\| = \max_{l=1, \dots, n} d(u_{a_l}, w_{b_l}). \quad (8)$$

在传统的FAROMF算法中, 相似性度量通常使用欧氏距离. 欧氏距离的计算要求待匹配信号具有相同的长度, 且特征点一一对应. 其计算公式为

$$d_E(y, d) = \sqrt{\sum_{l=1}^n (y_l - d_l)^2}, \quad (9)$$

然而, 欧氏距离对时间序列的长度和特征点位置非常敏感, 导致在处理长度不一致或局部特征点不对齐的信号时, 匹配效果不佳. 为了克服欧氏距离的局限性, 本文将弗雷歇距离引入到AROMF中. 弗雷歇距离可以灵活处理曲线长度差异和非线性变形, 定义如下:

$$d_F(y, d) = \min_{l=1, \dots, n} \max_{l=1, \dots, n} d(u_{a_l}, w_{b_l}). \quad (10)$$

将弗雷歇距离作为AROMF输出信号与监督信号的迭代误差距离来进行模式相似度匹配, 其引入AROMF后的迭代误差距离如(11)所示:

$$E_i^S = \sum_{j=1}^v (\min_{l=1, \dots, n} (\max_{l=1, \dots, n} d_j(u_{il}, w_{il})))^2, \quad (11)$$

其中: v 代表数据降维后的维度, u_i 代表第 i 个模式的模板信号. 首先, 通过LPP算法对信号进行降维处理, 从而获得各个模式的模板信号和待测试的信号. 接着, 对于选取的未知模式的测试信号, 在多个模板信号的监督下, 利用FAROMF对其进行形态变换, 生成不同的输出信号. 随后, 通过计算每个输出信号与各模板信号之间的迭代误差距离, 确定与待测试信号匹配程度最优的模板信号类型. 最终, 距离最小的模板信号将被判定为测试信号的模式类型. FAROMF模式匹配方法如图1所示.

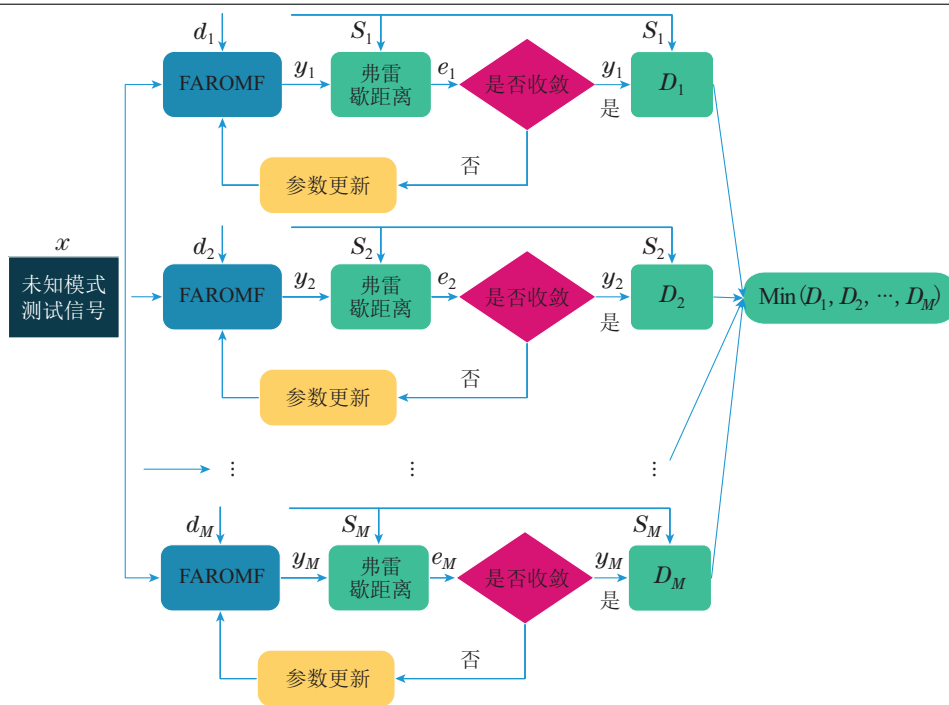


图 1 FAROMF模式匹配方法

Fig. 1 FAROMF pattern matching method

2.3 基于LPP-FAROMF的故障诊断流程

离线建模阶段:

- 1) 对TEP得到的原始数据集进行去噪和归一化处理;
- 2) 对处理过的数据, 利用LPP算法来对数据进行降维, 提取出数据的关键特征, 将不同的故障模式分为训练集和测试集, 得到基于LPP的转换矩阵;
- 3) 分别将不同故障模式的训练数据与获得的转换矩阵相乘, 得到不同故障模式的模板信号;
- 4) 分别将不同故障模式的测试数据与获得的转换矩阵相乘, 得到不同未知故障类型的测试信号。

在线诊断阶段:

- 1) 在不同故障模式的模板信号监督下对将要识别、分类的测试信号进行FAROMF形态变化, 得到输出信号;
- 2) 对得到的每个模板信号和与之对应的输出信号进行基于弗雷歇距离的迭代误差距离计算;
- 3) 找到最小的迭代误差距离, 而与之对应的模板信号就是未知测试信号的类型。

基于弗雷歇距离的 AROMF 的故障诊断原理图如图2所示。

3 案例与实验结果分析

3.1 TEP

TEP是一个应用于实际工艺流程的化工厂仿真模型, 其所生成的数据集具备时变、强耦合和非线性特性. 该数据集通常作为过程监测和故障诊断领域的基

准数据源, 被广泛应用于评估复杂工业过程的控制策略以及故障诊断模型的性能^[15]. 图3为TEP流程图。

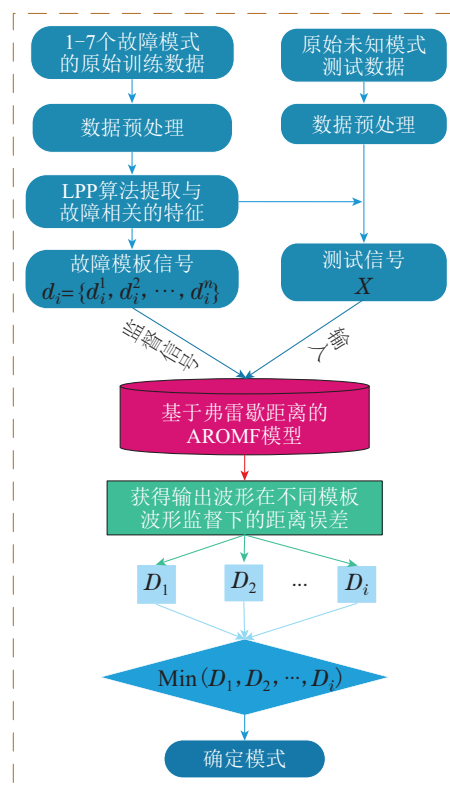


图 2 LPP-FAROMF的故障诊断原理图

Fig. 2 Fault diagnosis schematic of LPP-FAROMF

TEP主要分为5个单元, 分别是反应器、冷凝器、循环压缩机、气液分离器和汽提塔. 在TEP仿真模拟的整个过程中, 主要有8种成分产生, 分别是A, B, C,

D, E, F, G和H, 对于该过程气体反应剂A, D和E直接进入反应釜进行反应, C和D通过冷凝器进入过程. TEP具有52个过程变量, 包括从XMS(1)–XMS(41)的

41个过程测量变量和从XMV(1)–XMV(11)的共11个操作变量, 其中: 11个操作变量作为输入, 测量变量F, G和H作为该过程的输出变量^[16].

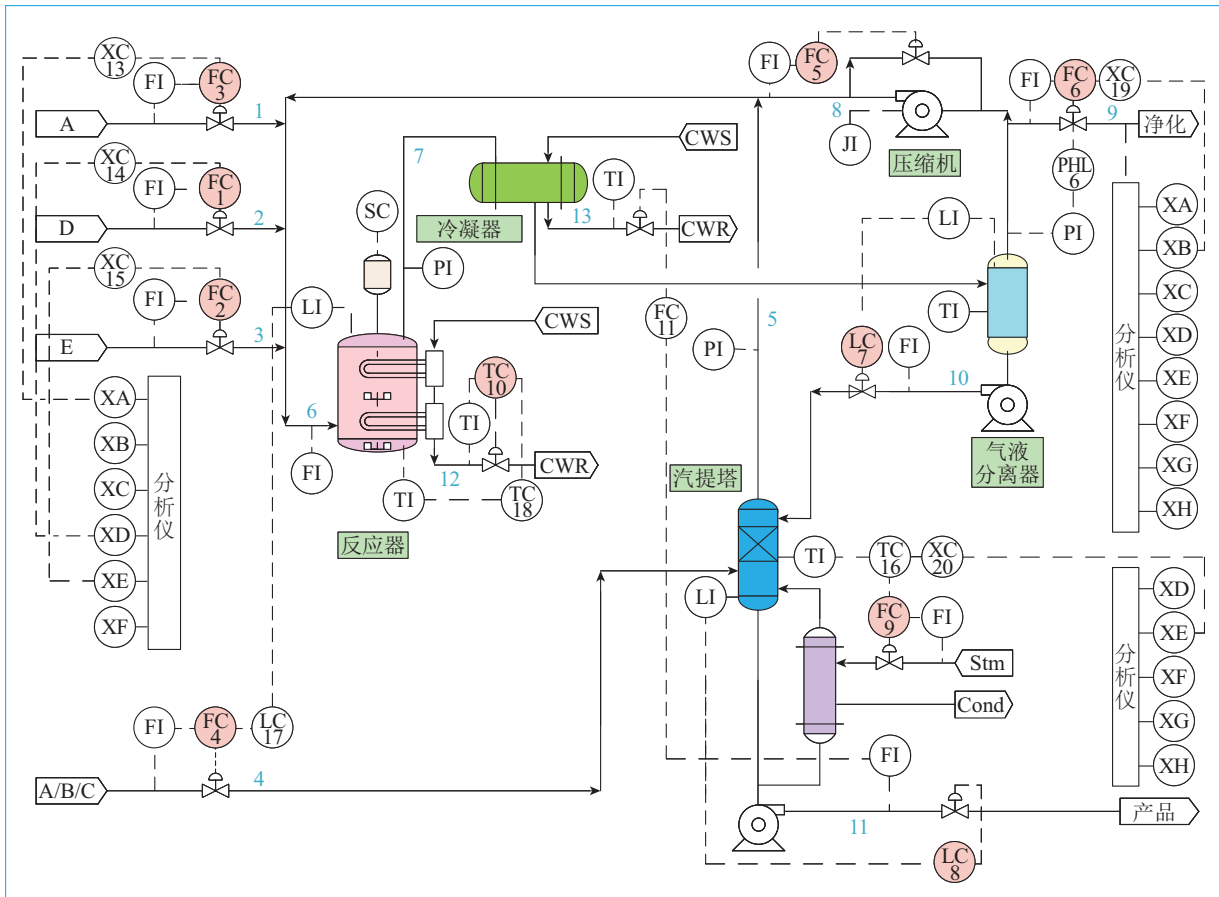


图3 TEP流程图

Fig. 3 TEP flowchart

3.2 LPP-FAROMF算法在TEP过程的验证

TEP仿真平台一共模拟了21种不同类型的故障, 为了与文献[14]中的研究结果进行对比, 选取了故障F1至F6, 同时在此基础上增加了故障F7, 以扩展研究范围并验证算法的鲁棒性. 这些故障涵盖了传感器故障、执行器故障和过程扰动, 具有代表性和多样性. 通过这一选择, 合理控制实验规模和复杂度, 确保了实验结果的代表性和可比性, 从而能够更深入地分析LPP-FAROMF算法的有效性. 每个故障类型选择500个训练数据和200个测试数据, 故障的详细描述如表1所示.

首先, 对各种故障类型的训练数据使用LPP算法进行特征提取, 选取前4个特征向量构成模板信号, 最终生成了7个故障模式的模板信号如图4所示.


图4所示为LPP算法特征提取后各个故障的信号趋势. 从图4中可以看出, 不同故障模式的模板信号在同一特征维度上有不同的趋势和形态变化. 然而, 对于同一类型的故障模式, 模板信号在各个特征维度上

的趋势和变化是相似的, 这也是使用FAROMF进行模式匹配的理论基础. 在获得7个故障模板信号后, 利用LPP算法获得待匹配的测试信号. 为了验证基于弗雷歇距离的AROMF在信号匹配中的优越性, 本文选取TEP中的故障5作为测试信号, 并分析其与模板信号在FAROMF处理前后的匹配效果. 故障5测试信号在4个特征方向上与模板信号的匹配过程如图5所示.



表1 故障案例选择和故障描述

Table 1 Fault case selection and fault description



故障ID	故障描述	故障类型
F1	A/C进料比、B成分恒定(液流4)	阶跃
F2	B成分、A/C进料比恒定(液流4)	阶跃
F3	D进料温度(液流2)	阶跃
F4	反应釜冷却水入口温度	阶跃
F5	冷凝器冷却水入口温度	阶跃
F6	A进料损失(液流1)	阶跃
F7	C集管压力损失-可用性降低(液流4)	阶跃





(a) 故障1





(d) 故障4





(b) 故障2




(e) 故障5



(c) 故障3



(f) 故障6






图4 LPP降维后的7个故障模式信号图

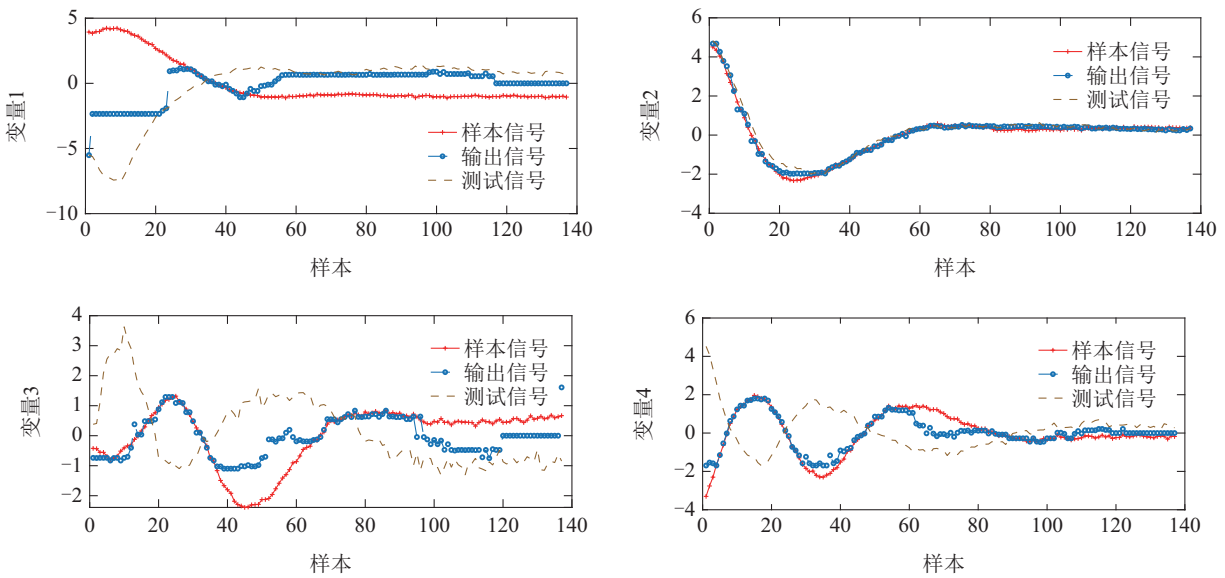
Fig. 4 The seven fault mode signal graphs after dimensionality reduction of LPP

对故障5测试信号匹配进行分析. 对得到的故障5模板信号进行 FAROMF 形态变换运算, 得到输出信号, 并根据弗雷歇距离计算输出信号与故障5测试信号的误差距离, 将4个特征向量的误差之和作为总误差距离. 从仿真结果可以得出, 故障1到故障7的监

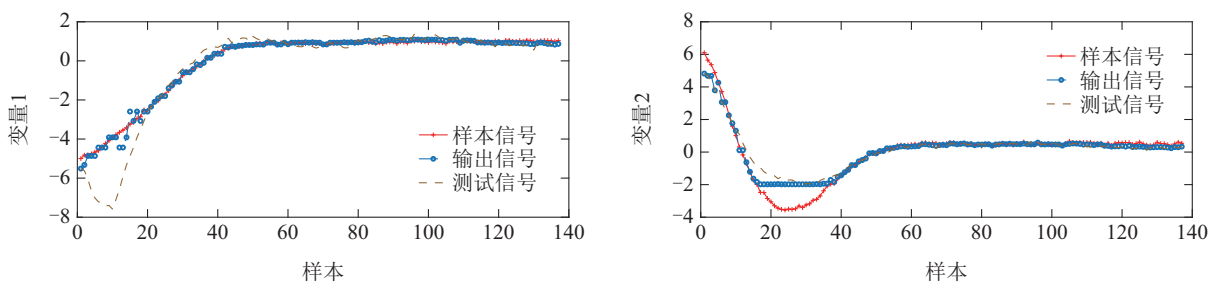
督信号与测试信号故障5的输出信号的距离分别为 32.48, 10.28, 6.63, 5.6, 4.47, 13.75, 7.04. 很显然最小值为4.47, 因此故障模式为故障5. 其他故障的诊断流程同上, 不同故障测试信号到模板故障信号的误差距离如表2所示.

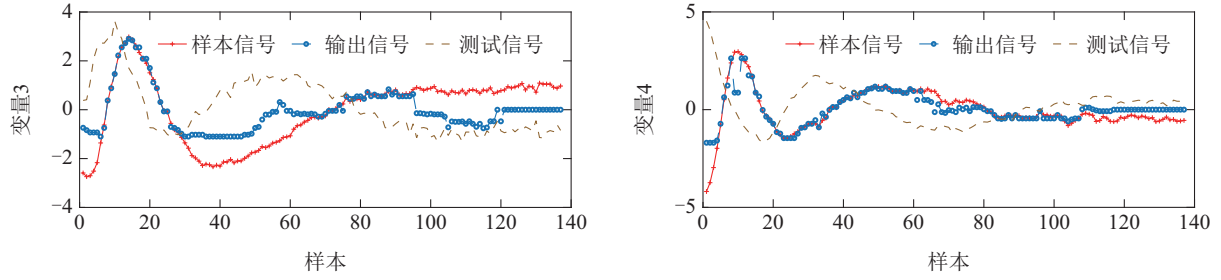
由表2可以看出故障1, 2, 4, 6之间的距离相差较大, 这样可以很容易地区分这几类故障. 而对于故障3, 5, 7, 它们之间的误差距离相差较近. 因此, 相较于故障1, 2, 4, 6难以区分, 但是从分类结果可以看出, 基于弗雷歇距离的AROMF故障诊断方法能够对这几类故障做到准确分类. 对此本文又对没有改进之前的LPP-AROMF做了仿真实验, 以此来对改进之后的距离作对比. 基于欧氏距离的不同故障测试信号到模板故障信号的误差距离如表3所示.

由表3可以看出, 同样是故障5, FAROMF 得出的迭代距离是4.47, AROMF 得出的迭代距离是11.01. 因此, FAROMF信号匹配方法对于两个信号之间的相似度有较高提升, 两个信号之间的迭代距离越小说明两个信号之间的相似度越高, 每次分类中出现错误的概率越小. 同时相较于AROMF也有较高的灵敏度. 故障诊断的灵敏度越高, 则出现错误分类的概率越小. 证明了FAROMF具有较高的分类精度.

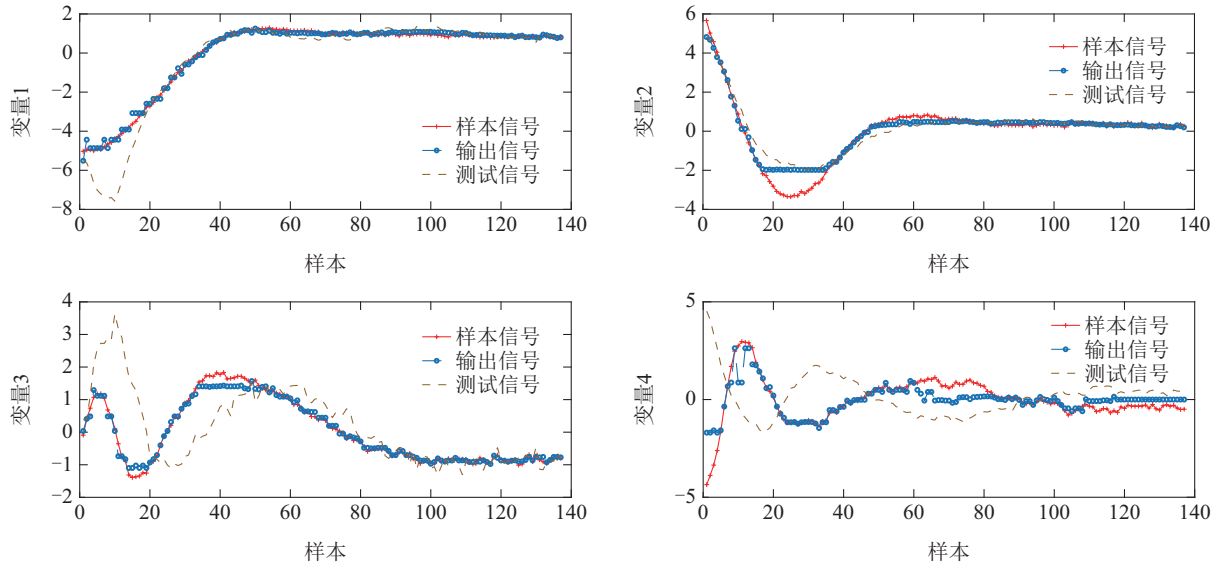


(a) 故障5在模板信号故障1监督下FAROMF结果

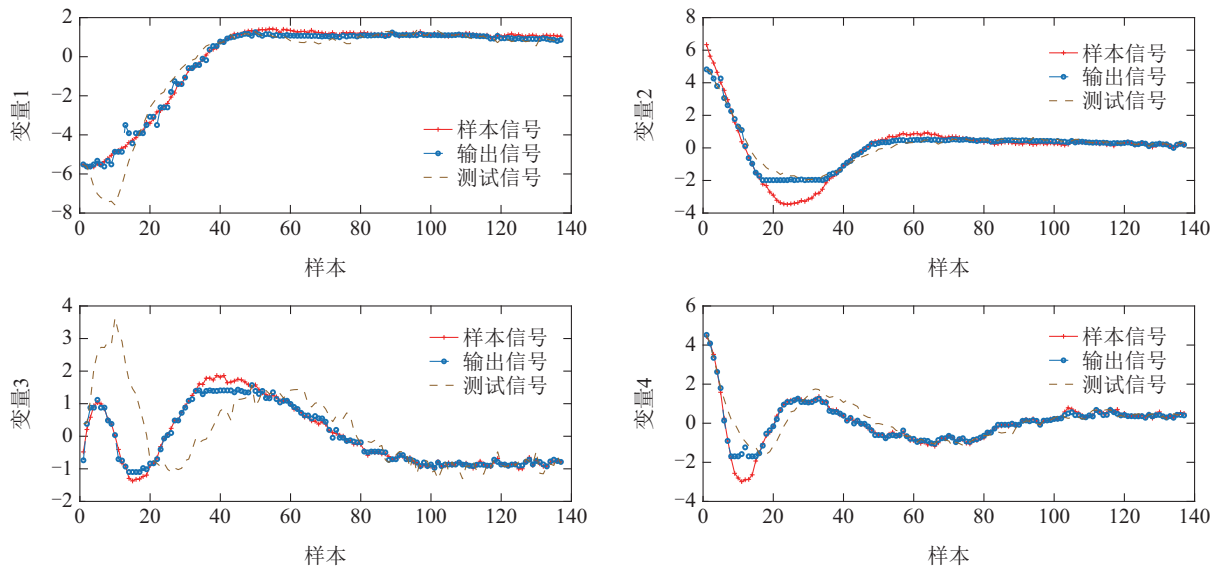




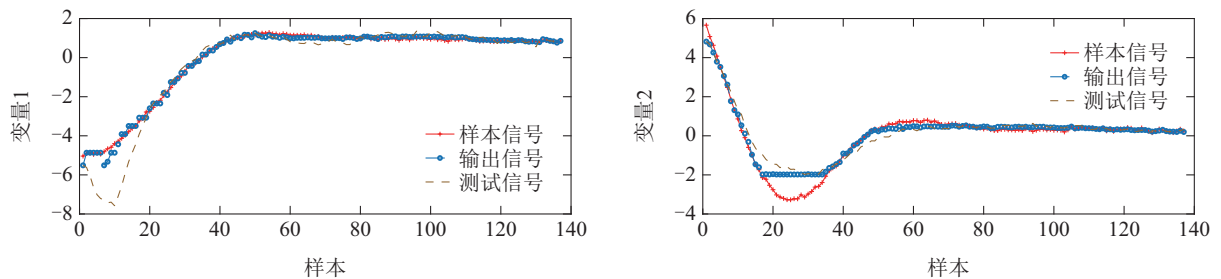
(b) 故障5在模板信号故障2监督下FAROMF结果

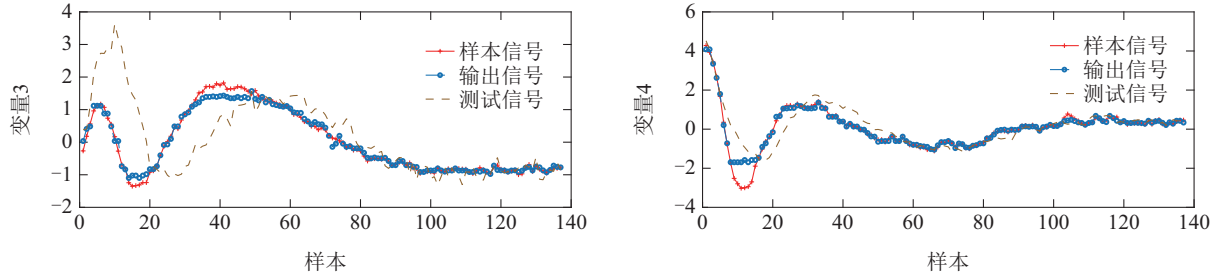


(c) 故障5在模板信号故障3监督下FAROMF结果

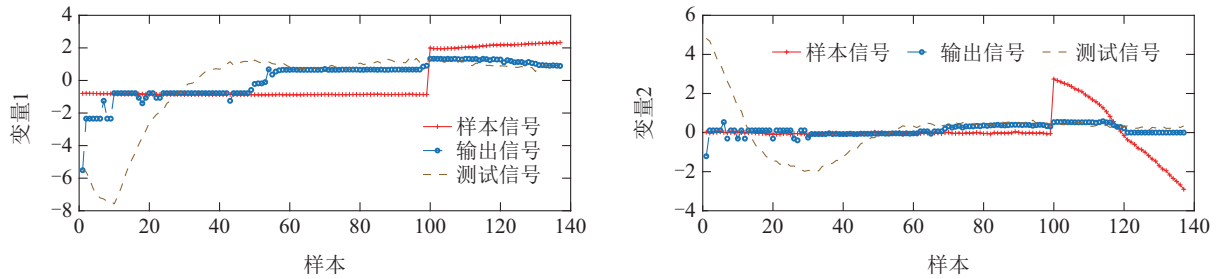


(d) 故障5在模板信号故障4监督下FAROMF结果

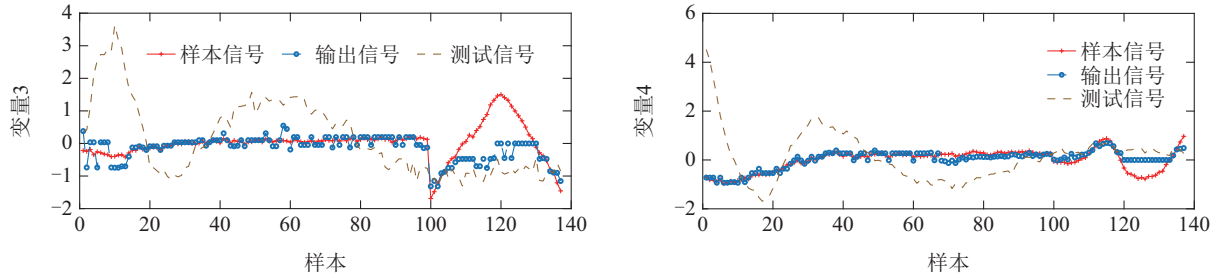




(e) 故障5在模板信号故障5监督下FAROMF结果



(f) 故障5在模板信号故障6监督下FAROMF结果



(g) 故障5在模板信号故障7监督下FAROMF结果

图5 故障5的模式匹配

Fig. 5 Pattern matching for fault 5

如果噪声发生明显的变化时,故障检测方法也认为系统发生异常.为了分析所提方法的抗噪声性能,因此在本文的研究中添加了不同的噪声干扰实验.利用不同信噪比(signal-to-noise ratio, SNR)(例如, SNR = 15 dB, 20 dB, 25 dB, 30 dB 和35 dB)对抗干扰

性能进行评估.在仿真实验中,本文选择了具有代表性的、难以区分的故障模式5作为研究对象,并向其添加了不同水平的噪声,故障诊断结果如表4所示.

从表4中可以看出,即使在存在噪声干扰的情况下,LPP-FAROMF方法依然能够保持较高的诊断准确

率,且与未加噪声的原始数据相比,其诊断准确率的下降幅度相对较小.一方面可以看出,随着信噪比的增大,故障诊断精度提高,当信噪比达到35 dB时,故障诊断精度接近原始数据的精度;另一方面,从表4的故障诊断结果中可以明显看到,与LPP-AROMF相比,LPP-FAROMF对不同SNR的故障诊断精度更高,进一步凸显了所提方法在处理噪声干扰方面的优势.所提LPP-FAROMF在不同信噪比下均能实现较好的诊断性能,以上结果表明,该方法在抗噪声方面具有一定的能力.

表2 基于弗雷歌距离的不同故障测试信号到模板故障信号的误差距离

Table 2 Error distance from different fault test signals to template fault signals based on Fréchet distance

误差距离	E1	E2	E3	E4	E5	E6	E7
F1	17.91	37.8	39.05	42.55	38.97	27.39	33.05
F2	39.59	5.27	9.97	11.37	10.98	16.95	13.73
F3	46.01	8.26	5.54	11.27	11.12	23.87	5.69
F4	49.81	13.67	14.63	6.26	12.49	26.67	22.51
F5	32.48	10.28	6.63	5.6	4.47	13.75	7.04
F6	22.64	20.21	22.09	24.55	22.24	3.81	26.7
F7	32.52	8.67	7.56	8.41	7.32	15.03	5.98

表3 基于欧氏距离的不同故障测试信号到模板故障信号的误差距离

Table 3 Error distance from different fault test signals to template fault signals based on Euclidean distance

误差距离	E1	E2	E3	E4	E5	E6	E7
F1	22.5	71.11	69.47	70.95	66.61	54.21	73.61
F2	54.75	14.77	24.03	29.41	29.98	41.61	33.24
F3	57.5	21.79	13.29	20.3	19.33	43.57	13.43
F4	73.25	37.58	33.49	12.35	21.06	56.44	49.97
F5	47.22	23.53	15.66	12.35	11.01	31.98	14.16
F6	55.13	63.75	59.73	63.43	58.98	7.22	59.85
F7	50.03	27.62	24.26	26.93	23.36	33.72	14.17

此外,还进行了对比实验,以证明所提方法的优越性.本文采用检测率衡量所提方法的性能.故障检测率(fault detection rate, FDR)是指检测出来的故障样本数占总故障样本数的比值.对于本文所研究的7个故障类型,各自重新选取100个故障样本使用LPP-FAROMF方法以及其他降维方法进行多组仿真实验来进行对比,其中故障诊断的方法包括PCA-AROMF^[17], KCVA-AROMF^[18], LPP-AROMF^[14],这些故障诊断方法诊断结果如表5所示.

表4 不同SNR下的故障模式5的故障诊断结果
Table 4 Fault diagnosis results for fault mode 5 with different SNRs

诊断精度	PCA-AR-OMF/%	KCVA-AR-OMF/%	LPP-AR-OMF/%	LPP-FAR-OMF/%
Without	19	30	65	86
SNR(15 dB)	6	13	45	78
SNR(20 dB)	5	18	47	81
SNR(25 dB)	9	20	50	83
SNR(30 dB)	11	21	49	83
SNR(35 dB)	11	23	53	87

表5 LPP-FAROMF方法与其他故障诊断方法的诊断精度比较
Table 5 Comparison of diagnostic accuracy of LPP-FAROMF method with other fault diagnosis methods

诊断精度	PCA-AROMF/%	KCVA-AROMF/%	LPP-AROMF/%	LPP-FAROMF/%
F1	97	100	100	100
F2	96	100	100	100
F3	40	52	55	85
F4	45	60	80	100
F5	19	30	70	86
F6	93	100	100	100
F7	33	45	75	92
平均值	60.57	69.57	82.86	94.71

通过仔细分析表5中得到的故障诊断结果,可以清晰地看到LPP-FAROMF方法在故障诊断准确率上展现出了显著的优势.特别是在故障5的识别分类上,该方法达到了86%的准确率,这一结果远高于其他故障诊断方法.与此同时,与其他降维方法相比,LPP能够有效提取高维度非线性数据中的关键特征,这对于后续的故障诊断至关重要,而FAROMF在模式分类方面也展现出良好的性能,使得LPP-FAROMF方法能够更准确地识别不同类型的故障,这进一步印证了LPP-FAROMF方法在故障诊断中的卓越表现.同时,为了更全面地评估LPP-FAROMF方法的性能,本文还对LPP-AROMF与LPP-FAROMF在不同故障下运行100次的时间进行了比较,如表6所示.

由表6可以看出,LPP-FAROMF方法对于不同故障的运行时间平均值为222 s,而LPP-AROMF方法为231 s,明显短于LPP-AROMF方法,这是由于弗雷歌距离考虑了曲线上的整体形状和路径,而不仅仅关注曲线上对应点之间的距离.它通过比较两个曲线的最优对齐路径来度量相似性,复杂度降低,因此能够降低运行时间,提高诊断的时效性.

表6 LPP-AROMF与LPP-FAROMF方法不同故障运行100次时间比较

Table 6 Comparison of LPP-AROMF and LPP-FAROMF methods for 100 run times with different faults

t/s	F1	F2	F3	F4	F5	F6	F7	平均值
LPP-AROMF	235	227	234	240	232	230	220	231
LPP-FAROMF	229	222	219	233	224	220	210	222

4 结论

本文针对LPP-AROMF方法在解决复杂的动态流程工业过程中故障模式匹配因曲线长度或参数化差异导致的匹配难题,提出了一种基于弗雷歇距离的LPP-AROMF故障诊断方法.该方法首先根据各类故障的参考曲线得到模板曲线,然后根据基于弗雷歇距离定义的相似度函数,计算待识别曲线与各模板曲线的相似度,将相似度最大的模板曲线所对应的故障模式作为待识别曲线的诊断结果输出,降低算法运算时间,增加故障识别率.该方法在TEP上验证了所提出方法的性能.本文所提出的方法具有较高的故障诊断准确度和较快的故障诊断速度,同时具有更好的鲁棒性,适用于多故障诊断过程.

在本文研究过程中,还存在一些值得关注的问题.首先,在局部保留投影中,LPP的最近邻参数仍然可以进一步优化.其次,在未来的工作中,可以考虑将当前热门的智能优化算法如人工神经网络、强化学习、模拟退火算法等与LPP-FAROMF相结合,进一步提高故障诊断的准确率.

参考文献:

- [1] LIU L, WANG L. Research on nonlinear process fault detection based on generative LLE and SVDD. *The 8th International Conference on Intelligent Informatics and Biomedical Sciences (ICIBMS)*. Okinawa, Japan: IEEE, 2023, 8: 31 – 36.
- [2] WANG N, YANG F, ZHANG R, et al. Intelligent fault diagnosis for chemical processes using deep learning multimodel fusion. *IEEE Transactions on Cybernetics*, 2022, 52(7): 7121 – 7135.
- [3] HUANG K, WU S, LI Y, et al. A multi-rate sampling data fusion method for fault diagnosis and its industrial applications. *Journal of Process Control*, 2021, 104: 54 – 61.
- [4] HE Y L, ZHAO Y, HU X, et al. Fault diagnosis using novel AdaBoost based discriminant locality preserving projection with resamples. *Engineering Applications of Artificial Intelligence*, 2020, 91: 103631.

- [5] YANG J, BAO W, LIU Y, et al. Joint pairwise graph embedded sparse deep belief network for fault diagnosis. *Engineering Applications of Artificial Intelligence*, 2021, 99: 104149.
- [6] JIANG Y, YIN S, KAYNAK O. Performance supervised plant-wide process monitoring in industry 4.0: A roadmap. *IEEE Open Journal of the Industrial Electronics Society*, 2021, 2: 21 – 35.
- [7] YAN Xiaona. *Research base on improved discriminant locality preserving projections method and its application in industrial fault diagnosis*. Beijing: Beijing University of Chemical Technology, 2021. (闫晓娜. 基于改进判别局部保持投影方法的研究及其工业故障诊断应用. 北京: 北京化工大学, 2021.)
- [8] CAO S, HU Z, LUO X, et al. Research on fault diagnosis technology of centrifugal pump blade crack based on PCA and GMM. *Measurement*, 2021, 173: 108558.
- [9] WANG Y L, WU D Z, YUAN X F. LDA-based deep transfer learning for fault diagnosis in industrial chemical processes. *Computers & Chemical Engineering*, 2020, 140: 106964.
- [10] ZHANG Y X, FAN Y, LI Z. Application of wavelet packet and kernel partial least squares method for ball bearing fault detection. *Light Ind Machinery*, 2023, 41(3): 60 – 65.
- [11] FAN S, ZHANG X M, SONG Z H. Imbalanced sample selection with deep reinforcement learning for fault diagnosis. *IEEE Transactions on Industrial Informatics*, 2022, 18(4): 2518 – 2527.
- [12] WANG A G, ZHAO S H, LIU J J, et al. Locality adaptive preserving projections for linear dimensionality reduction. *Expert Systems with Applications*, 2020, 151: 113352.
- [13] CHEDED L, DORAISWAMI R. A novel integrated framework for fault diagnosis with application to process safety. *Process Safety and Environmental Protection*, 2021, 154: 168 – 188.
- [14] XU Y, WANG Z X, KE W, et al. A fault diagnosis approach integrated LPP with AROMF for process industry. *The 11th Data Driven Control and Learning Systems Conference (DDCLS)*. Chengdu, China: IEEE, 2022: 734 – 739.
- [15] JIANG Q C, YAN S F, CHENG H, et al. Local-global modeling and distributed computing framework for nonlinear plant-wide process monitoring with industrial big data. *IEEE Transactions on Neural Networks and Learning Systems*, 2020, 32(8): 3355 – 3365.
- [16] LIU X, HE H. Fault diagnosis for TE process using RBF neural network. *IEEE Access*, 2021, 9: 118453 – 118460.
- [17] XU Y, JIANG X, KE W, et al. A novel pattern classification integrated GLPP with improved AROMF for fault diagnosis. *Process Safety and Environmental Protection*, 2023, 171: 299 – 311.
- [18] SONG X M, LIU Q L, DONG M X, et al. Chemical process alarm root cause diagnosis method based on the combination of data-knowledge-driven method and time retrospective reasoning. *ACS Omega*, 2022, 7(24): 20886 – 20905.

作者简介:

雷海 硕士研究生, 目前研究方向为故障诊断, E-mail: leihai@bistu.edu.cn;

曹健 副教授, 目前研究方向为故障诊断、流程工业知识自动化, E-mail: caojian@bistu.edu.cn;

李擎 教授、博士生导师, 目前研究方向为自主系统、智能导航与控制, E-mail: liqing@bistu.edu.cn.