

控制与决策

Control and Decision

基于多特征融合的工业气动调节阀快速自学习故障诊断方法

代伟, 黄金昊, 王聪, 杨春雨

引用本文:

代伟, 黄金昊, 王聪, 杨春雨. 基于多特征融合的工业气动调节阀快速自学习故障诊断方法[J]. *控制与决策*, 2023, 38(10): 2934–2942.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2022.0178>

您可能感兴趣的其他文章

Articles you may be interested in

[基于广义主成分分析的重构故障子空间建模方法](#)

Reconstructed fault subspace modelling method based on generalized principal component analysis

控制与决策. 2021, 36(4): 808–814 <https://doi.org/10.13195/j.kzyjc.2019.0818>

[基于核典型相关性-熵成分分析的工业过程质量监测方法](#)

A quality monitoring method for industrial process based on kernel canonical correlation-entropy component analysis

控制与决策. 2021, 36(12): 2999–3006 <https://doi.org/10.13195/j.kzyjc.2020.0548>

[标签Petri网的路径信息在故障诊断中的应用](#)

Application of path information of labeled Petri nets in fault diagnosis

控制与决策. 2021, 36(2): 325–334 <https://doi.org/10.13195/j.kzyjc.2019.0698>

[高超声速飞行器间歇故障改进自适应容错控制](#)

Improved adaptive fault-tolerant control of intermittent faults in hypersonic flight vehicle

控制与决策. 2021, 36(11): 2627–2636 <https://doi.org/10.13195/j.kzyjc.2020.0483>

[基于不变网络模型和故障注入的分布式信息系统故障溯源方法](#)

Fault source location algorithm for distributed information system based on invariant network and fault injection

控制与决策. 2020, 35(11): 2723–2732 <https://doi.org/10.13195/j.kzyjc.2019.0214>

基于多特征融合的工业气动调节阀 快速自学习故障诊断方法

代伟[†], 黄金昊, 王聪, 杨春雨

(中国矿业大学 信息与控制工程学院, 江苏 徐州 221116)

摘要: 气动调节阀的复杂特性,使得通过建立精确数学模型来描述阀门故障较为困难,因而数据驱动技术在其故障诊断领域颇受关注.但现有商业化的调节阀其控制系统仅配置了相当有限的硬件设备,这对故障诊断模型和学习效率提出了更高的要求.为此,提出一种基于多特征融合的气动调节阀快速自学习故障诊断方法.首先,提出基于云模型 (cloud model, CM) 和动态内部主元分析 (dynamic-inner principal component analysis, DiPCA) 的特征信息融合方法,提高诊断模型的输入信息质量;其次,建立一种低差异随机配置网络,按照低差异序列以监督增量方式快速自主构造调节阀诊断模型,从而有效提高模型的学习效率和紧致性;最后,利用 DAMADICS 平台的实验数据验证所提出方法的快速性和准确性.

关键词: 调节阀; 故障诊断; 快速自学习; 云模型; 动态内部主元分析; 随机配置网络

中图分类号: TP206.3

文献标志码: A

DOI: 10.13195/j.kzyjc.2022.0178

引用格式: 代伟,黄金昊,王聪,等. 基于多特征融合的工业气动调节阀快速自学习故障诊断方法[J]. 控制与决策, 2023, 38(10): 2934-2942.

Fast self-learning fault diagnosis method for industrial pneumatic control valves based on multi-feature fusion

DAI Wei[†], HUANG Jin-hao, WANG Cong, YANG Chun-yu

(School of Information and Control Engineering, China University of Mining and Technology, Xuzhou 221116, China)

Abstract: The complex characteristics of pneumatic control valves make it difficult to describe valve faults by establishing an accurate mathematical model, data-driven technology thus attracts widespread attention in the field of its fault diagnosis. The existing control systems of commercial regulating valves, however, are always equipped with limited hardware equipment, which puts forward higher requirements for the fault diagnosis model and learning efficiency. Therefore, this paper presents a fast self-learning fault diagnosis method for pneumatic control valves based on multi-feature fusion. Firstly, by integrating the cloud model (CM) and dynamic-inner principal component analysis (DiPCA), a fault feature fusion method of pneumatic control valves is proposed to improve the quality of input information for the diagnosis model. Then, a low discrepancy stochastic configuration network is established to construct the diagnosis model quickly and autonomously in a supervised incremental manner according to the low discrepancy sequence, effectively improving the learning efficiency and compactness of the model. Finally, experimental data from the DAMADICS platform are employed to verify the rapidity and accuracy of the proposed method.

Keywords: control valves; fault diagnosis; fast self-learning; cloud model; DiPCA; stochastic configuration networks

0 引言

工业调节阀作为工业流体输送系统中的主要控制单元,是保证工业生产安全、系统平稳运行至关重要的一环,其具有性能稳定、响应敏捷等优点.但由于频繁的机械动作以及输送介质的强腐蚀性等恶劣工

况的影响,调节阀容易出现各类故障^[1].这些故障轻则影响工业生产,重则威胁人民生命财产安全.因此,提高对调节阀的故障诊断能力对保证工业流体输送系统安全稳定运行具有重要意义^[2].当前的主流方法包括基于解析模型的方法、基于专家知识的方法和

收稿日期: 2022-01-25; 录用日期: 2022-05-17.

基金项目: 国家自然科学基金面上项目(61973306); 江苏省自然科学基金项目(BK20200086); 江苏省研究生科研与实践创新计划项目(SJCX22_1128); 中国矿业大学研究生创新计划项目(2022WLJRCZL097).

责任编辑: 赵春晖.

[†]通讯作者. E-mail: weidai@cumt.edu.cn.

数据驱动的方法^[3]。

基于解析模型的诊断方法是在调节阀机理结构基础上,结合质量流量和动力学理论^[4]、气动声学 and 涡运动理论^[5]、压力场和湍射流理论^[6]等相关知识,充分分析调节阀的输入输出特性,建立故障诊断的数学解析模型。其优点是从解析模型上能够直观描述故障的特性,但由于不同工况下的输入量和干扰因素存在差异,往往难以建立精确、普适的解析模型^[7],在实际应用中存在一定的局限性。

基于专家知识的诊断方法,通过建立专家知识库对故障进行推理和诊断,避免了对精确数学模型的依赖。如:文献[8]基于专家规则建立了故障树,分析了溢流阀故障成因,并基于CLIPS开发了溢流阀的专家诊断系统。文献[9]介绍了一种基于模糊逻辑的非线性故障诊断系统,从模糊规则库中选取可接受性度量最大的作为诊断结果。文献[10]通过粒子群算法对专家规则中判定故障发生所对应信号的阈值进行优化,经实验平台的数据验证了改进后的方法对故障诊断准确率的提高。由于专家规则是从系统运行过程中总结挖掘的成功经验,具有更高的实际应用价值,但是规则的制定依赖于人的经验,模型的学习能力有限,处理未知情况的能力差,且当专家规则数量很多时,其搜索会降低系统的响应速度。

近年来,随着各类智能算法迅速兴起,数据驱动的方法引起了学者们的广泛关注。其主要思想是通过智能算法对过程数据进行挖掘,建立特定对象的数据模型。文献[11]通过集成经验模态分解和光谱滤波从电机电流和气缸振动信号中提取相应的特征信息,分析了压缩机气阀发生泄漏时对激励和响应的影响,使用支持向量机(support vector machine, SVM)实现对不同程度压缩机气阀泄漏故障模式的分类。文献[12]将过程变量和控制输出两组离散时间信号转换为单个向量,作为多层前馈网络的输入,提出一种粘滞性检测网络对阀门的粘滞状态进行诊断。文献[13]以电液伺服阀的进油压差和出油压差归一化后作为网络的输入,对比了BP神经网络、RBF神经网络、Elman神经网络故障诊断的实时性和准确性。文献[14]首先对多传感器采集的故障信息进行特征降噪,然后基于欧氏距离和最大相关最小冗余方法进行特征提取,最后基于DS论据和卷积神经网络(convolutional neural networks, CNN)对决策信息进行融合。数据驱动的方法以过程数据为基础,不需要建立精确的解析模型,同时此类方法不依赖专家知识,建立的模型学习能力更强。由于神经网络算法具备

从数据中推断未知关系的能力,在数据驱动的故障诊断方法中应用广泛,鉴于此,本文研究依托神经网络开展气动调节阀故障诊断方法研究。

直接基于神经网络建立调节阀故障诊断模型普遍存在3个难题。其一,需要结合特征提取器实现故障诊断,但由于外界环境和噪声的干扰、数据采集和信息加工过程的影响等原因,调节阀故障信息具有不确定性^[15],常用的特征提取方法如主成分分析^[16]、快速傅里叶变换^[17]等缺乏挖掘不确定性信息的能力^[18];其二,网络结构的构建往往依赖于经验或实验,难以确定最优的网络结构,缺少在线自主调整结构的能力;其三,用于建立网络诊断模型的学习算法建模过程耗时,以基于梯度方法的神经网络算法为例,在误差梯度曲面的平坦区域内,权值误差变化很小,使得算法的收敛速度较慢。

受上述3个问题驱动,本文针对工业气动调节阀特性,提出一种基于多特征融合的快速自学习故障诊断方法。首先,在能够有效处理定性概念和定量论域双向转换的不确定性问题的云模型(cloud model, CM)基础上,考虑到调节阀在系统运行过程中处于动态的开-闭状态,提出一种基于云模型和动态内部主元分析(dynamic-inner principal component analysis, DiPCA)特征融合的策略;其次,采用随机配置网络(stochastic configuration networks, SCN)建立网络诊断模型,以增量方式自主地向网络添加新的节点^[19],系统在线运行时,当诊断模型与阀门特性不匹配时,在现有模型基础上,可快速重新调整网络结构和参数,实现诊断模型的在线快速自学习;最后,采用低差异序列生成随机数代替传统SCN的伪随机数配置隐含层参数,以避免伪随机序列重复采样现象导致生成冗余节点,从而有效提高诊断模型的紧致性,进一步加快模型学习速度。

1 气动调节阀故障分析

根据控制执行器的不同,工业调节阀主要可分为气动调节阀、电动调节阀和自力式调节阀等。气动调节阀因其结构紧凑、流量特性精确等优点得到了广泛的应用,本文主要针对气动调节阀的故障诊断进行研究。图1为气动调节阀的工作原理。控制器给定信号CV,执行机构根据CV控制阀杆位移,定位器通过位移传感器测量阀杆位移,经内部控制器计算位移残差,再由E/P转换器将电信号转换成气动信号操作执行结构,实现对阀杆位移的精确定位,以控制调节阀的开度。




图1 气动调节阀工作原理

气动调节阀故障种类与故障成因繁杂,根据气动调节阀故障特性,一般可分为突变故障、衰变故障和快变故障3类。

突变故障是指故障信号变化速率大,且与正常信号表现出明显差异的一类故障,故障强度越大,差异越明显。常见的突变故障包括阀杆阻力异常、介质蒸发、定位器反馈故障等。以阀杆阻力异常为例,当出现机械结构异常时,阀杆位移的距离受限于某一区间内,不能下降到指定位置,进而使得对调节阀开度的控制出现偏差,最终影响运输介质的流速。

衰变故障的故障信号变化速率小,且与正常信号整体趋势一致,随着时间积累才有所差异,如阀座阻塞、杆位移传感器故障等。以阀座阻塞为例,由于混进流体介质中的固体颗粒在阀座上堆积,阀杆最大位移量及阀座的孔口尺寸减小,进一步使得流量系数的减

小,最终导致介质流速的异常变化。

快变故障的故障信号只在局部表现出异常而又很快与正常信号趋于一致,这类故障包括介质意外压力变化和定位器供应压降等。以介质意外压力变化为例,由于调节阀本身或外部的某些原因,阀体内流体介质的上游和下游间的压差发生意外改变,使得运输介质的流量和流速受到影响,流动产生的力也会随之变化,进而影响阀杆的位置。

通过上述分析可以看出,阀杆位移和介质流速信号蕴含着不同类别故障的潜在信息。因此,本文主要通过对上述两种信号的探究,挖掘其与不同故障间的深层次关系,实现对气动调节阀故障的诊断。然而,调节阀的控制执行单元相对复杂,故障原因和故障方式表现出成分错杂的特点,这对故障特征的有效提取提出了更高的要求。由于检测设备的局限性、环境的复杂性、信息采集方法的不完善性等因素,表征调节阀故障状态的信息存在随机性和模糊性等不确定性问题^[20]。这些问题会影响提取故障特征信息的准确性,从而降低故障诊断的精度,故对于故障信息中的不确定性成分进行有效提取十分重要。

2 气动调节阀快速自学习故障诊断方法

本文所提出的基于多特征融合的工业气动调节阀快速自学习故障诊断方法如图2所示。该方法由基于CM-DiPCA的多特征融合和基于低差异SCN的故障诊断模型两部分组成。

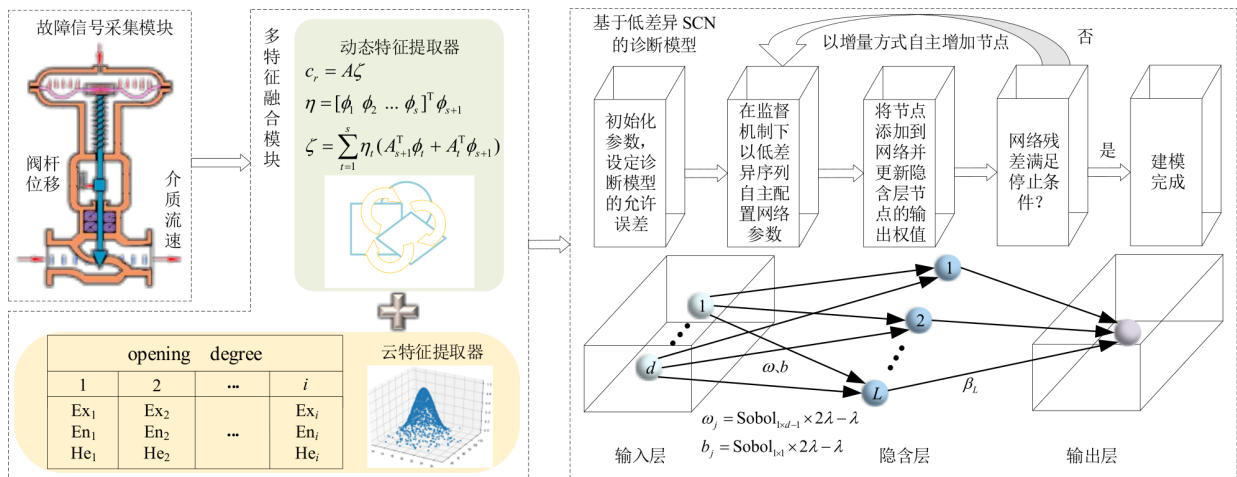


图2 系统框图

2.1 基于CM-DiPCA的多特征融合方法

熵作为不确定性的量度,能够较好地描述信息的不确定性,但近似熵^[21]和样本熵^[22]在故障特征提取时存在参数选择复杂和阈值敏感等问题。因此,本文提出基于云模型(cloud model, CM)和动态内部主

元分析(dynamic-inner principal component analysis, DiPCA)的多特征融合方法。

CM是一种处理不确定性问题的有效工具,不仅特征维度低,计算复杂度小,而且其特征熵不依赖于参数设定,从而可有效避免上述问题。文献[23]通过

CM对故障齿轮箱的振动信号提取特征信息,准确地实现了对齿轮箱故障类型的识别,并证明了用CM提取故障特征的有效性.然而,调节阀在工业系统中通过不同程度的开合状态控制流体介质的传输,实质上是一个时间序列上的动态开闭过程,故障信号中蕴含着大量动态特征信息,仅依靠CM特征信息训练的模型缺乏对动态过程的模拟,导致模型测试结果不稳定. DiPCA可根据样本数据的自相关和互相关关系确定其动态关系,是一种有效的动态特征提取方法. 本文使用DiPCA从故障信号中筛选出贡献度较高的动态主元补充到云模型特征值之中,增加其对动态信息的捕捉,改善其稳定性.

考虑到不同位置的故障形式存在差异,本文以调节阀不同的开度作为切入点,采用分档测试的方式获取故障数据,以深入挖掘其故障特性从而实现对不同形式故障的区分. 分档测试:从控制器输出为0%开始,以开度的 $\sigma\%$ 作为差值增量变化,经历 $m = \text{INT}(100/\sigma) + 1$ 个不同开度状态,直至达到100%. 每次变化后均保持一段时间,每个开度下分别采集 n 个阀杆位移和介质流速数据组成一个样本. 以阀杆位移信号为例,在某一故障模式 f 下共进行 N 次分档测试,可得样本 $A = [a_1, a_2, \dots, a_N]^T$. 其中

$$a_k = \underbrace{[a_{k,1}, \dots, a_{k,n}, \dots, a_{k,n \times (m-1)+1}, \dots, a_{k,m \times n}]^T}_{a_k^1} \underbrace{\dots}_{a_k^m}$$

$k = 1, 2, \dots, N$, 每个采样数据称为故障信息云滴.

基于不同开度下的故障信息云滴以及逆向云算法^[24]计算故障云特征值. 首先,由第 i 个开度下的 n 个云滴求出期望 Ex_k^i ,即

$$\text{Ex}_k^i = \frac{1}{n} \sum_{q=n \times (i-1)+1}^{n \times i} a_{k,q}. \quad (1)$$

计算一阶中心矩,并求出熵 En_k^i ,即

$$\text{En}_k^i = \sqrt{\frac{\pi}{2}} \times \frac{1}{n} \sum_{q=n \times (i-1)+1}^{n \times i} |a_{k,q} - \text{Ex}_k^i|. \quad (2)$$

进一步求出超熵 He_k^i ,即

$$\text{He}_k^i = \sqrt{\frac{1}{n-1} \sum_{q=n \times (i-1)+1}^{n \times i} (a_{k,q} - \text{Ex}_k^i)^2 - (\text{En}_k^i)^2}. \quad (3)$$

$$\text{令 } B_k = \underbrace{[\text{Ex}_k^1, \text{En}_k^1, \text{He}_k^1, \dots, \text{Ex}_k^m, \text{En}_k^m, \text{He}_k^m]}_{B_k^1} \dots \underbrace{\dots}_{B_k^m}$$

则 N 个样本经上述步骤可得故障云特征序列 $B = [B_1, B_2, \dots, B_N]^T$.

其后,利用DiPCA提取动态特征. 将 A 去均值并按方差为1标准化,初始化 ζ 为随机单位向量,从 A 中

取少量数据并根据文献[25]所述交叉验证法确定主元个数 l 和动态阶次 s ,对样本矩阵 A 进行如下处理: 令 $A_t = [a_t, a_{t+1}, \dots, a_{Z+t-1}]^T, t = 1, 2, \dots, s + 1, Z + s = N$. 定义 $c_r = A\zeta = [c_{r,1}, c_{r,2}, \dots, c_{r,Z+s}]^T$ 为从 A 中提取的第 r 个动态主元, $r = 1, 2, \dots, l, \zeta$ 为负载向量,引入向量 $\phi_t = [c_{r,t}, c_{r,t+1}, \dots, c_{r,Z+t-1}]^T$.

迭代以下步骤直至收敛:

$$c_r = A\zeta; \quad (4)$$

$$\eta = [\phi_1 \ \phi_2 \ \dots \ \phi_s]^T \phi_{s+1}; \quad (5)$$

$$\zeta = \sum_{t=1}^s \eta_t (A_{s+1}^T \phi_t + A_t^T \phi_{s+1}); \quad (6)$$

$$\zeta = \frac{\zeta}{\|\zeta\|}, \eta = \frac{\eta}{\|\eta\|}. \quad (7)$$

更新样本数据

$$A = A - c_r p^T, \quad (8)$$

$$p = A^T c_r / c_r^T c_r, \quad (9)$$

当提取到 l 个动态主元时算法结束.

设 $C = [c_1, c_2, \dots, c_l], c_l$ 表示提取的第 l 个动态主元. 令 $X = [B \ C]^T = [x_1, x_2, \dots, x_N]^T$, 则 X 即为在故障模式 f 下所采集的阀杆位移信号经过CM-DiPCA特征信息融合后的故障特征序列.

2.2 基于低差异SCN故障诊断模型

SCN是一种监督型单隐层增量式随机学习模型,其可以从一个零节点或固定节点的单隐层网络开始,通过监督机制逐个随机产生新的节点并添加到网络,同时优化网络参数,直到模型性能达到满足期望精度为止^[26],具有学习速度快、泛化能力强、网络拓扑结构由数据自主确定的特性. 本文采用SCN建立调节阀故障诊断模型,实现诊断模型的在线快速自学习.

传统SCN采用伪随机数构造候选节点池并从中选取最优节点以加快算法的收敛速度,而随机特性容易产生冗余节点. 这些低质量节点不仅对网络模型性能贡献不大,还使学习效率降低,构造出的网络模型尺寸大于任务需要,导致网络结构不紧致. 相对于伪随机序列而言,低差异序列具有更好的均匀性,降低了重复探索的概率,故本文提出以低偏差序列替代伪随机序列对SCN进行改进. 常用的低差异序列包括Sobol序列、Faure序列、Halton序列等. 由于Faure序列和Halton序列在进行高维运算时存在相关性,难以取得理想的结果^[27],本文采用Sobol序列用于配置SCN隐含层参数.

以气动调节阀故障诊断模型为例,低差异SCN的建模过程如下:

令 $X \in R^{N \times d}, Y \in R^N$ 分别为输入输出矩阵, $X = [x_1, x_2, \dots, x_N]^T, x_N \in R^d$ 表示上述特征信息融合后的特征序列中第 N 条维数为 d 的调节阀故障信息, d 的取值为云特征的个数与动态主元个数之和. $Y = [y_1, y_2, \dots, y_N]^T, y_N \in R$ 为故障标签. 假设已经构建好一个带有 $L-1$ 个隐含层节点的调节阀故障诊断模型, 其输出表示为

$$y_{L-1}(x) = \sum_{j=1}^{L-1} \beta_j g_j(\omega_j^T x + b_j). \quad (10)$$

其中: β_j 表示第 j 个隐含层节点与输出层之间的输出权值; $g_j(\cdot)$ 表示第 j 个隐含层节点的激活函数; ω_j 和 b_j 分别表示在监督机制下由 Sobol 序列配置 T_{\max} 次隐含层参数后, 从中选取的使监督变量 ξ 最优时的第 j 个隐含层节点的输入权值和偏置, 即

$$\omega_j = \text{Sobol}_{1 \times d-1} \times 2\lambda - \lambda, \quad (11)$$

$$b_j = \text{Sobol}_{1 \times 1} \times 2\lambda - \lambda. \quad (12)$$

当前网络的残差 $e_{L-1} = y - y_{L-1}$, 若 $\|e_{L-1}\|$ 大于设定的容忍误差, 则说明当前训练所得的网络不能满足故障诊断要求. 此时, 网络以自主的方式增加一个隐含层节点, 在监督机制的约束条件下重新配置隐含层参数并更新输出权值 β_L , 监督机制的约束条件为

$$\xi_L = \frac{\langle e_{L-1}^T(X) \cdot h_L(X) \rangle^2}{h_L^T(X) \cdot h_L(X)} \quad (13)$$

$$(1 - r - \mu_L) e_{L-1}^T(X) e_{L-1}(X) \geq 0; \quad (14)$$

$$\mu_L = \frac{1-r}{L+1}, \quad r \in (0, 1); \quad (14)$$

$$h_L(X) = [g_L(\omega_L^T x_1 + b_L), \dots, g_L(\omega_L^T x_N + b_L)]^T. \quad (15)$$

其中: h_L 为第 L 个隐含层节点的输出向量, r 和 μ_L 均为收缩参数.

第 L 个隐含层节点建立后的网络输出为

$$y_L(x) = y_{L-1}(x) + \beta_L g_L(\omega_L^T x + b_L). \quad (16)$$

若此时所得残差满足设定要求, 则建模完成; 否则, 继续在监督机制下以自主的方式增加隐含层节点, 直至满足要求.

为验证低差异序列相较于伪随机序列对于 SCN 算法性能的提升, 本文通过公共数据集比较低差异 SCN 与传统 SCN 的模型参数. 节点池容量 T_{\max} 均设定为 50, 临界容忍误差均设定为 0.15, 对 50 组实验取均值进行分析, 其结果如表 1 所示.

从表 1 结果可以看出, 在相同参数设置下, 低差异 SCN 构建的网络所用节点数更少, 从而使得网络

表 1 节点池容量 $T_{\max} = 50$ 时的对比实验

数据集	配置方式	节点数	学习时间/s	测试精度/%
Abalone	伪随机	153.04	1.62	93.36
	Sobol	150.96	1.59	93.43
Texture	伪随机	34.78	0.87	91.30
	Sobol	33.85	0.84	91.40
Penbased	伪随机	44.55	0.60	83.76
	Sobol	44.30	0.60	84.08
Segment	伪随机	149.80	2.50	87.09
	Sobol	146.44	2.49	87.29

结构更加紧致, 同时学习时间和测试精度相较于传统 SCN 也有所改善, 算法性能更好. 通常情况下, 快速性与准确性存在一定的矛盾, 但对于本文方法, 其采用 Sobol 序列探索隐层节点参数, 使得随机产生的模型参数在空间中分布更为均匀, 有效避免了几何空间距离相近的冗余节点的产生, 从而提高了增量过程中隐层节点的质量, 最终使学习速度和准确性均有所提高.

3 实验结果和分析

3.1 实验设置

本实验所用的初始数据集由 DAMADICS 平台仿真产生, 控制信号以阀杆允许运动的总行程的 25% 作为差值变化, 从控制器输出为 0% 起, 依次变化为 25%、50%、75%、100%, 共经历了 5 个不同的开度状态. 共选取表 2 中的 9 种故障模式加上 1 种正常模式, 采集阀杆位移 X_s 和介质流速 F 两类数据组成初始数据集. 每类模式最终各得到 180 组特征信息, 其中 120 组作为训练集, 60 组作为测试集.

表 2 实验所选故障

故障名称及表示	故障特性	一般成因
阀杆阻力异常 f_1	突变	机械因素异常
阀座沉淀或阻塞 f_2	衰变	异物堆积
介质蒸发 f_3	突变	局部压力异常
隔膜穿孔 f_4	突变	隔膜材料磨损等
杆位移传感器故障 f_5	衰变	电位计受损等
定位器反馈故障 f_6	突变	机械杆反馈系统异常等
定位器供应压降 f_7	快变	气源供应异常
介质意外压力变化 f_8	快变	阀体和外部异常
阀体内部泄露 f_9	衰变	内部受侵蚀或老化

3.2 实验对比与分析

通过对各故障模式下的初始故障数据进行对比发现, 在控制器输出信号为 0% 和 25% 时, 所有故障模式的介质流速信号数据均相同, 这意味着提取的云

模型特征值是冗余的,考虑到减小特征向量的维度,故将这两个状态下的故障云特征值去除,最终在分档测试下共得到故障云特征8组,如表3所示.对提取出

的5组阀杆位移和3组介质流速故障云特征分别采用文献[28]提到的“软或”算法进行提升,绘制出的云模型云图如图3所示,将各故障模式概念可视化.

表3 各模式下的云模型特征值

label	CM features	group 1	group 2	group 3	group 4	group 5	group 6	group 7	group 8
f_0	Ex	0.001 0	0.239 1	0.500 0	0.762 4	0.983 2	0.713 2	0.212 7	0.017 3
	En	0.001 5	0.028 1	0.033 8	0.043 8	0.034 4	0.120 7	0.068 9	0.031 1
	He	0.001 2	0.040 2	0.041 2	0.043 7	0.041 0	0.013 7	0.088 8	0.034 7
f_1	Ex	0.001 0	0.231 6	0.249 6	0.249 9	0.250 1	0.999 5	0.999 5	0.999 5
	En	0.001 3	0.031 1	0.001 6	0.001 1	0.001 6	0.000 6	0.000 8	0.000 9
	He	0.000 9	0.042 2	0.002 1	0.000 5	0.000 4	0.000 1	0.000 3	0.000 1
f_2	Ex	0.000 8	0.240 4	0.502 1	0.764 3	0.844 6	0.307 8	0.084 5	0.005 8
	En	0.001 3	0.031 3	0.038 2	0.050 3	0.011 4	0.087 5	0.031 7	0.011 7
	He	0.001 1	0.041 4	0.042 3	0.045 0	0.016 0	0.113 3	0.038 6	0.015 2
f_3	Ex	0.000 4	0.112 6	0.293 2	0.298 3	0.297 8	0.999 3	0.999 5	0.999 5
	En	0.000 7	0.131 7	0.010 0	0.003 6	0.003 6	0.000 9	0.000 8	0.000 8
	He	0.000 2	0.071 5	0.008 8	0.001 3	0.001 3	0.000 3	0.000 3	0.000 2
f_4	Ex	0.000 4	0.161 8	0.417 6	0.530 0	0.542 3	0.858 0	0.665 0	0.640 6
	En	0.000 7	0.125 0	0.098 0	0.093 8	0.087 1	0.191 3	0.310 6	0.300 6
	He	0.000 2	0.045 1	0.021 1	0.038 0	0.037 1	0.079 4	0.150 3	0.137 2
f_5	Ex	0.000 9	0.246 1	0.507 3	0.767 7	0.989 9	0.999 3	0.995 1	0.658 8
	En	0.001 3	0.030 9	0.032 7	0.035 8	0.017 4	0.000 9	0.010 0	0.103 6
	He	0.001 2	0.039 5	0.037 4	0.038 0	0.034 0	0.000 3	0.011 1	0.027 2
f_6	Ex	0.009 2	0.141 8	0.498 9	0.985 5	0.999 2	0.595 2	0.013 5	0.000 7
	En	0.016 4	0.220 0	0.329 0	0.032 0	0.001 0	0.445 0	0.029 4	0.000 9
	He	0.005 7	0.063 7	0.134 0	0.038 6	0.000 4	0.225 9	0.033 0	0.000 3
f_7	Ex	0.000 7	0.222 8	0.447 6	0.542 6	0.547 7	0.835 5	0.637 8	0.624 1
	En	0.001 0	0.050 5	0.071 9	0.083 2	0.079 0	0.194 8	0.289 0	0.279 9
	He	0.000 8	0.046 2	0.032 8	0.035 9	0.034 4	0.102 3	0.132 7	0.125 9
f_8	Ex	0.000 4	0.209 3	0.483 9	0.737 5	0.964 7	0.999 3	0.361 4	0.056 9
	En	0.000 7	0.069 3	0.038 2	0.048 8	0.056 6	0.000 9	0.134 1	0.079 9
	He	0.000 2	0.042 1	0.042 3	0.043 9	0.038 1	0.000 3	0.125 7	0.032 5
f_9	Ex	0.001 0	0.239 1	0.500 0	0.762 4	0.983 2	0.999 3	0.999 5	0.998 8
	En	0.001 5	0.028 1	0.033 8	0.043 8	0.034 4	0.000 9	0.000 8	0.001 9
	He	0.001 2	0.040 2	0.041 2	0.043 8	0.041 1	0.000 3	0.000 3	0.002 0

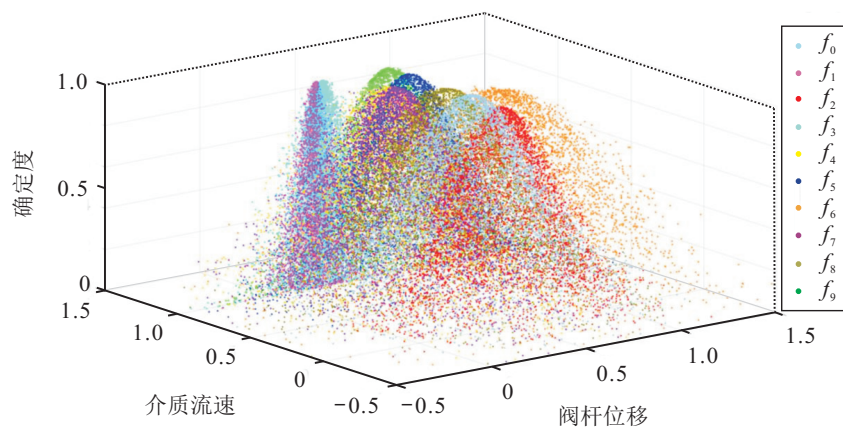


图3 各故障模式在云特征空间中的云图

从图3中可以看出,基于不同开度下阀杆位移和介质流速信号提取出的云模型特征值,能够在云特征空间中较好地实现对10种调节阀状态中多数类别的区分,这表明以调节阀不同的开度作为切入点,通过故障云特征来挖掘不同故障特性这一方法是具备有效性和可行性的.但同时也可以看到, f_4 与 f_7 、 f_5 与 f_9 仍有较高的相似度,仅依靠云特征值建立的诊断模

型可能影响诊断结果的准确性和稳定性.在解决该问题的研究过程中,本文考虑到调节阀的动态工作特性,故采用DiPCA提取动态特征与不同开度下的故障云特征进行多特征融合.一方面,降低了云特征的相似性对诊断结果的不利影响;另一方面,增强了模型对动态信息的捕捉能力,同时提高了对样本信息的利用率.

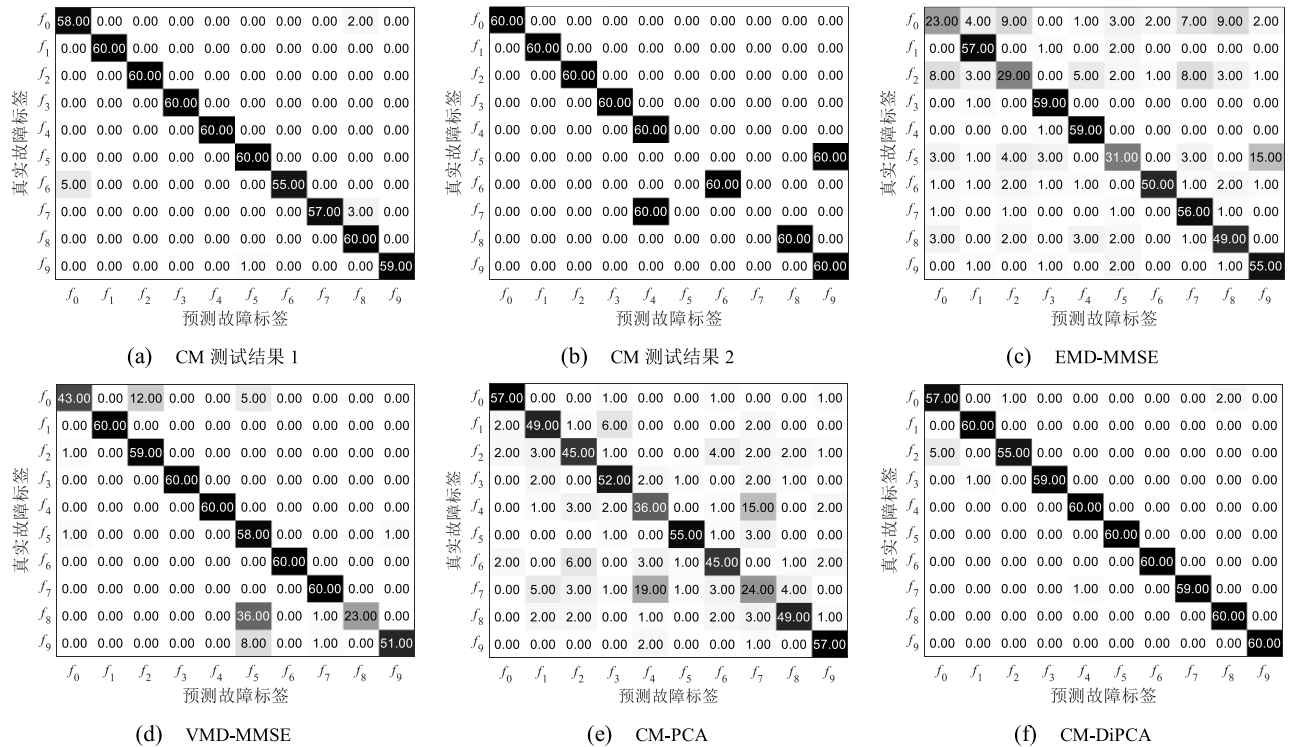


图4 不同特征提取方法的测试结果混淆矩阵

为了验证本文所提出特征融合方法的有效性,依次选取CM、EMD-MMSE^[29]、VMD-MMSE^[30]、CM-PCA、CM-DiPCA 五种特征提取方法,均采用低差异SCN作为分类算法进行多次实验对比,图4给出了最具代表性的结果,表4为5种特征提取方法结果比较.

表4 5种特征提取方法结果比较

特征提取方法	特征维度	测试精度 /%
CM	24	85±13
EMD-MMSE	50	76±2
VMD-MMSE	50	87±3
CM-PCA	54	78±3
CM-DiPCA	44	97±2

由上述实验对比可以看到:仅提取CM数字特征虽有高达98%的“高光表现”,但整体测试结果呈现出不稳定的趋势,甚至出现如图4(b)所示的故障5、故障7全部误诊断的情况,无法满足实际工况的要求;基于模态分解以去除噪声干扰,从多时间尺度提取

故障样本熵的思想非常适合调节阀的故障诊断,但由于EMD的模态混叠问题使得其表现不佳,而VMD-MMSE方法较难实现对本实验中个别故障的准确诊断,还需做进一步改进;CM-PCA方法相对于仅依靠CM特征的方法,提高了稳定性,但是整体的诊断结果依旧不够理想;CM-DiPCA方法与本实验中的其他特征提取方法相比,无论是测试精度还是稳定性都取得了最优的结果,从而表明了其作为一种新的特征提取方法的有效性.

此外,为了验证诊断学习算法的优越性,将上述经CM-DiPCA特征提取后的故障特征分别用SVM、BP、CNN、SCN、低差异SCN进行多次对比实验.其中:SVM算法核函数选择RBF函数,BP算法的学习率lr设置为0.01,CNN算法中MaxEpochs设置为18,MiniBatchSize设置为10,两种SCN算法的RMSE临界值为0.15, T_{max} 设置为50,结果如表5所示.实验所用SVM算法来自Matlab的libsvm工具箱,因不涉及参数的随机分配,故测试精度保持在90.00%,且

SVM算法在处理多分类问题上训练速度会受到影响;BP算法虽然最高测试精度高于SVM,模型训练更快,但整体平均测试精度只有88.33%,且性能不够稳定.从本实验来看,这两类方法均不能满足实际生产的要求.CNN算法在测试精度上取得了最好的效果,但是其复杂的网络结构使得训练时间远高于其他算法,在本研究背景下存在一定局限性.从表5中可以看出,本文提出的低差异SCN算法所用的训练时间最短,且具备较高的测试精度,整体来看在表5的几种算法中取得了最理想的结果.

表5 不同分类算法的结果比较

分类算法	最高测试精度/%	最低测试精度/%	平均测试精度/%	平均训练时间/s
SVM	90.00	90.00	90.00	0.625 0
BP	95.00	81.67	88.33	0.423 5
CNN	99.67	96.50	98.33	14
SCN	97.67	94.67	97.17	0.301 7
低差异SCN	99.00	95.33	97.50	0.255 6

4 结论

本文提出了一种基于多特征融合的气动调节阀快速自学习故障诊断方法,该方法包括基于CM-DiPCA的多特征融合和基于低差异SCN的故障诊断模型两个部分.在前一部分,首先根据逆向云算法,从调节阀故障数据中挖掘隶属于故障概念的不确定性特征信息;然后,利用动态内部主元分析法提取故障信号的动态特征信息与其进行特征融合作为诊断模型的输入.在后一部分,鉴于低差异序列比伪随机序列具有更好的均匀性,提出了一种基于Sobol序列的低差异随机配置网络算法,并基于此算法实现了对1类正常模式和9类故障模式的诊断.经实验对比,验证了本文所提出的特征提取方法解决了仅依靠云模型特征信息存在诊断结果不稳定的问题,同时相较于其他信息融合的特征提取方法,获取的特征更有效.此外,通过相同诊断样本下各分类算法的比较,验证了低差异随机配置网络算法精度高、学习速度快的优势,综合上述两个方面的实验对比,表明了本文所提出的调节阀故障诊断方法的准确性和快速性.

需要说明的是,本文所提出的方法是一种数据驱动的方法,实际中不同的故障点可能导致相似的故障数据,当故障数据特征表现相同时,本文方法难以进行故障溯源,从而无法更精确地识别这些故障.因此,将数据方法与机理知识相结合以进一步提高诊断模型质量是未来非常值得研究的工作.

参考文献(References)

- [1] 王印松, 吴军超. 一种基于PCA和贝叶斯分类的气动调节阀故障诊断方法[J]. 中国测试, 2019, 45(12): 112-118.
(Wang Y S, Wu J C. A fault diagnosis method for pneumatic regulating valve based on PCA and Bayesian classification[J]. China Measurement & Test, 2019, 45(12): 112-118.)
- [2] 陈林, 王兴松, 张逸芳, 等. 阀门故障诊断技术综述[J]. 流体机械, 2015, 43(9): 36-42.
(Chen L, Wang X S, Zhang Y F, et al. Survey of valve fault diagnostic technology[J]. Fluid Machinery, 2015, 43(9): 36-42.)
- [3] 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.)
- [4] 尚群立, 李梦强, 张晶瑜. 气动截止阀机理建模及其在阀门故障诊断中的应用[J]. 浙江工业大学学报, 2020, 48(2): 154-158.
(Shang Q L, Li M Q, Zhang J Y. Mechanism modeling of pneumatic cut-off valve and its application in fault diagnosis[J]. Journal of Zhejiang University of Technology, 2020, 48(2): 154-158.)
- [5] 张颖, 戴光, 赵俊茹, 等. 阻塞流下阀门内漏率的声学检测与计算[J]. 化工机械, 2006, 33(5): 296-299.
(Zhang Y, Dai G, Zhao J R, et al. Inspection and calculation of acoustics of the inner leakage rate of the valves under barrage flow[J]. Chemical Engineering & Machinery, 2006, 33(5): 296-299.)
- [6] 高倩霞, 李录平, 饶洪德, 等. 阀门泄漏率的声发射测定技术研究[J]. 动力工程学报, 2012, 32(1): 42-46.
(Gao Q X, Li L P, Rao H D, et al. Acoustic emission theory and testing technology for quantitative diagnosis of valve leakages[J]. Journal of Chinese Society of Power Engineering, 2012, 32(1): 42-46.)
- [7] Han X J, Jiang J, Xu A D, et al. Fault detection of pneumatic control valves based on canonical variate analysis[J]. IEEE Sensors Journal, 2021, 21(12): 13603-13615.
- [8] 许同乐, 韩元杰. 专家系统在液压故障诊断中的应用[J]. 机床与液压, 2009, 37(3): 182-184.
(Xu T L, Han Y J. The application of expert system in hydraulic fault diagnosis system[J]. Machine Tool & Hydraulics, 2009, 37(3): 182-184.)
- [9] Escobet A, Nebot À, Cellier F E. Fault diagnosis system based on fuzzy logic: Application to a valve actuator benchmark[J]. Journal of Intelligent & Fuzzy Systems, 2011, 22(4): 155-171.
- [10] Zhang D M, Hao J X, Chen L M, et al. Fault diagnosis approach for pneumatic control valves based on modified expert system[C]. The 19th International Symposium on Distributed Computing and Applications for Business Engineering and Science (DCABES). Xuzhou, 2020:

- 104-107.
- [11] Han L B, Jiang K S, Wang Q D, et al. Quantitative evaluation on valve leakage of reciprocating compressor using system characteristic diagnosis method[J]. *Applied Sciences*, 2020, 10(6): 1946.
- [12] Amiruddin A, Zabiri H, Jeremiah S S, et al. Valve stiction detection through improved pattern recognition using neural networks[J]. *Control Engineering Practice*, 2019, 90: 63-84.
- [13] 戚华峰. 基于神经网络技术的核电厂阀门故障诊断[D]. 哈尔滨: 哈尔滨工程大学, 2012: 45-52.
(Qi H F. Fault diagnosis of the nuclear power plant valve based on neural network technology[D]. Harbin: Harbin Engineering University, 2012: 45-52.)
- [14] Shi J C. Fault diagnosis in a hydraulic directional valve using a two-stage multi-sensor information fusion[J]. *Measurement*, 2021, 179: 109460.
- [15] Duan R X, Huang S J, He J J. Optimal fault diagnosis strategy for complex systems considering common cause failure under epistemic uncertainty[J]. *Engineering Computations*, 2021, 38(9): 3417-3437.
- [16] Lei Y F, Jiang W L, Jiang A Q, et al. Fault diagnosis method for hydraulic directional valves integrating PCA and XGBoost[J]. *Processes*, 2019, 7(9): 589.
- [17] Flett J, Bone G M. Fault detection and diagnosis of diesel engine valve trains[J]. *Mechanical Systems and Signal Processing*, 2016, 72/73: 316-327.
- [18] Zhao N Y, Mao Z W, Wei D H, et al. Fault diagnosis of diesel engine valve clearance based on variational mode decomposition and random forest[J]. *Applied Sciences*, 2020, 10(3): 1124.
- [19] Dai W, Zhou X Y, Li D P, et al. Hybrid parallel stochastic configuration networks for industrial data analytics[J]. *IEEE Transactions on Industrial Informatics*, 2022, 18(4): 2331-2341.
- [20] 徐晓滨. 不确定性信息处理的随机集方法及在系统可靠性评估与故障诊断中的应用[D]. 上海: 上海海事大学, 2009: 16.
(Xu X B. Stochastic set method for uncertain information processing and its application in system reliability evaluation and fault diagnosis[D]. Shanghai: Shanghai Maritime University, 2009: 16.)
- [21] Yan R, Gao R X. Approximate entropy as a diagnostic tool for machine health monitoring[J]. *Mechanical Systems and Signal Processing*, 2007, 21(2): 824-839.
- [22] Zhang W B, Su Y P, Zhou Y J, et al. Intelligent gear fault recognition method based on HWP sample entropy and grey incidence[J]. *Advanced Materials Research*, 2013, 706/707/708: 1397-1400.
- [23] Han L, Li C W, Liu H C. Feature extraction method of rolling bearing fault signal based on EEMD and cloud model characteristic entropy[J]. *Entropy*, 2015, 17(12): 6683-6697.
- [24] Cao H, Zhang J D. Cloud model-based intelligent evaluation method in marine engine room simulator[J]. *IEEE Access*, 2020, 8: 168502-168515.
- [25] Dong Y N, Qin S J. A novel dynamic PCA algorithm for dynamic data modeling and process monitoring[J]. *Journal of Process Control*, 2018, 67: 1-11.
- [26] Dai W. Stochastic configuration networks with block increments for data modeling in process industries[J]. *Information Sciences*, 2019, 484: 367-386.
- [27] Niederreiter H. Recent constructions of low-discrepancy sequences[J]. *Mathematics and Computers in Simulation*, 2017, 135: 18-27.
- [28] 阎高伟, 龚杏雄, 李国勇. 基于振动信号和云推理的球磨机负荷软测量[J]. *控制与决策*, 2014, 29(6): 1109-1114.
(Yan G W, Gong X X, Li G Y. Soft sensor for ball mill fill level based on vibration signal and cloud model reasoning[J]. *Control and Decision*, 2014, 29(6): 1109-1114.)
- [29] Zhang Q, Que P, Chen T, et al. A new multi-sensor data fusion algorithm based on EMD-MMSE[J]. *Journal of Shanghai Jiao Tong University*, 2007(2): 153-158.
- [30] Dora C, Biswal P K. An improved algorithm for efficient ocular artifact suppression from frontal EEG electrodes using VMD[J]. *Biocybernetics and Biomedical Engineering*, 2020, 40(1): 148-161.

作者简介

代伟(1984—), 男, 教授, 博士, 从事智能与数据驱动的复杂工业过程建模、运行优化控制理论、随机神经网络与学习系统、增量联邦学习、工业大数据分析等研究, E-mail: weidai@cumt.edu.cn;

黄金昊(1994—), 男, 硕士生, 从事云模型理论、故障诊断等研究, E-mail: TS20060142P31@cumt.edu.cn;

王聪(1996—), 男, 硕士, 从事神经网络、故障诊断等研究, E-mail: TS18060192P31@cumt.edu.cn;

杨春雨(1979—), 男, 教授, 博士, 从事智能系统控制技术、奇异摄动系统优化控制等研究, E-mail: chunyu yang@cumt.edu.cn.