DOI: 10.3901/JME.2020.18.007

数据驱动的聚类分析故障识别方法研究*

王庆锋 刘家赫 卫炳坤 张程

(北京化工大学高端机械装备健康监控及自愈化北京市重点实验室 北京 100029)

摘要: 设备故障预测与健康管理的智能化时代,从设备状态监测数据中分析、提取故障特征信息,实现故障自动识别与分类是实现故障自愈调控的前提。以离心压缩机为研究对象,基于 K-means 聚类分析和数据驱动方法,构建 K-means 聚类故障模式识别模型,筛选故障识别灵敏度高的故障特征参数作为模型输入参数,基于监测数据训练得到不同故障的聚类中心,探索数据驱动的基于聚类中心距离判据的离心压缩机故障识别方法。应用中石油某公司离心压缩机正常和喘振、碰摩、不对中故障案例数据进行模型验证,结果表明:监测数据驱动的聚类分析故障识别方法能够实现离心压缩机多故障模式自动识别;与支持向量机故障识别方法相比, K-means 聚类分析故障识别模型准确性更高;数据驱动方法计算实时监测数据聚类中心,利用直观距离判据实现故障模式自动识别,能够实现故障诊断和智能决策实现,为开展自愈调控提供技术支撑。

关键词: 数据驱动; 聚类分析; 故障识别; 自愈调控; 故障特征参数

中图分类号: TH17

Research on Data-driven Clustering Analysis Fault Identification Method

WANG Qingfeng LIU Jiahe WEI Bingkun ZHANG Cheng

(Beijing Key Laboratory of Health Monitoring and Self-recovery of High-end Machinery Equipment,
Beijing University of Chemical Technology, Beijing 100029)

Abstract: Equipment fault prediction and health management have entered the era of intelligence. It is the premise to realize fault self-recovery regulation by analysing and extracting fault characteristic information from equipment condition monitoring data to realize automatic fault identification and classification. The centrifugal compressor is taken as the research object. Based on K-means clustering analysis and data-driven method, the K-means clustering fault pattern recognition algorithm model is constructed. The fault characteristic parameters with high sensitivity of fault identification are selected as model input parameters, and the clustering centers of different faults are obtained by monitoring data training, and the data-driven centrifugal compressor fault identification method based on the cluster center distance criterion is explored. The model is validated by the normal and surge, rubbing and misalignment case data of a centrifugal compressor of CNPC. The results show that the data-driven clustering fault identification method can realize the automatic identification of multi-fault mode of centrifugal compressor; compared with the support vector machine fault identification method, the K-means clustering analysis fault identification method is more accurate; the data-driven method calculates the clustering center of real-time monitoring data, and uses the intuitive distance criterion to realize automatic identification of fault modes, which can realize fault diagnosis and intelligent decision-making, and provide technical support for self-healing regulation.

Key words: data-driven; clustering analysis; fault identification; self-recovery regulation; fault characteristic parameters

0 前言

机电装备复杂系统监控一体化运行管理,实现故障早期预警、故障模式自动识别和故障靶向抑制、

故障特征参数自动调整,是开展故障自愈调控的关键技术基础。张明等^[1]研究了动态自学习阈值和趋势滤波的机械故障智能早期预警方法;何勇等^[2]研究了各类故障模式识别方法的诊断原理、特点及其应用;高金吉院士等^[3-4]研究了人工自愈与动力机械振动故障靶向抑制方法;潘鑫等^[5]研究了旋转机械气压液体式不平衡振动故障靶向自愈调控系统;赵

* 国家自然科学基金(51775029)、中国石化“石化装置关键机组远程诊断故障智能预警技术研究”(CHG18064)和中央高校基本科研业务费(PYBZ1813)资助项目。20191205 收到初稿,20200511 收到修改稿

志宏^[6]提出了机械故障特征提取与诊断方法;王峰^[7]研究了化工过程非正常工况自愈调控,阐述了化工过程复杂系统自愈调控理论;安晶等^[8]提出了一种一维卷积神经网络的旋转机械智能故障诊断方法;雷亚国等^[9]从信号获取、特征提取、故障识别与预测方面研究了机械智能故障诊断理论与方法。

机器的自愈化就是通过预防、抑制、康复、代偿等技术措施在无人干预下按设计的自愈机制自行抑制或消除故障。在设备故障诊断中,故障模式自动识别是较为关键的环节^[10],对开展故障自愈调控具有重要意义。如图 1 所示,在整个故障仿生自愈流程中,基于状态工况数据库,进行特征提取和故障模式识别是重要的一环,表现为提取信号的状态特征参数,以表征不同故障信号间的差异。故障模式识别常见的方法有神经网络^[11]、支持向量机^[12]和聚类分析等。神经网络算法的基础是基于渐进理论的传统统计学,只有在学习样本数目趋于无穷大时,其识别性能才有理论上的保证;支持向量机和聚类分析则更适合于有限样本的情况。聚类分析是一种不需要任何先验知识条件就能将样本进行自动分类的多元统计模式识别方法,它是一个无监督的观察式学习过程。该方法特别适用于无法获得故障数据样本或故障数据样本获取相对困难情况下的故障模式识别问题^[13]。

图 1 故障仿生自愈原理图

本文基于 K-means 聚类算法和模型训练学习、统计分析方法,开展离心压缩机喘振、碰摩和不对中多种故障模式识别方法探索研究,旨在为离心压缩机故障自愈调控提供技术支撑。

1 K-means 聚类算法

K-means 聚类是源于信号处理的一种向量量化方法,现在则更多地作为一种聚类分析方法流行于数据挖掘领域。K-means 聚类算法的目的是:把 n 个点划分到 k 个聚类中,使得每个点都属于离它最近的均值(此即聚类中心)对应的聚类中,以此作为聚类的标准。

以二维聚类为例,聚类步骤如下。

(1) 已知有 20 个样本,每个样本都有 2 个特征,使用 K-means 法实现样本分类(表 1)。

表 1 样本值

样本	x_1	x_2	x_3	x_4	x_5
特征 1	0	1	0	1	2
特征 2	0	0	1	1	1
样本	x_6	x_7	x_8	x_9	x_{10}
特征 1	1	2	3	6	7
特征 2	2	2	2	6	6
样本	x_{11}	x_{12}	x_{13}	x_{14}	x_{15}
特征 1	8	6	7	8	9
特征 2	6	7	7	7	7
样本	x_{16}	x_{17}	x_{18}	x_{19}	x_{20}
特征 1	7	8	9	8	9
特征 2	8	8	8	9	9

(2) 令 $K=2$,选初始聚类中心 $Z_1(1) = x_1 = (0,0)^T$, $Z_2(1) = x_2 = (1,0)^T$,如图 2 所示。

图 2 初始聚类中心

(3) 计算 x_1 到两个聚类中心的距离, $\|x_1 - Z_1(1)\| = \left\| \begin{pmatrix} 0 \\ 0 \end{pmatrix} - \begin{pmatrix} 0 \\ 0 \end{pmatrix} \right\| = 0$, $\|x_1 - Z_2(1)\| = \left\| \begin{pmatrix} 0 \\ 0 \end{pmatrix} - \begin{pmatrix} 1 \\ 0 \end{pmatrix} \right\| = 1$, 因为 $\|x_1 - Z_1(1)\| < \|x_1 - Z_2(1)\|$, 所以 $x_1 \in Z_1(1)$ 。再计算 x_2

到两聚类中心的距离， $\|x_2 - Z_1(1)\| = \left\| \begin{pmatrix} 1 \\ 0 \end{pmatrix} - \begin{pmatrix} 0 \\ 0 \end{pmatrix} \right\| = 1$ ，

$\|x_1 - Z_2(1)\| = \left\| \begin{pmatrix} 1 \\ 0 \end{pmatrix} - \begin{pmatrix} 1 \\ 0 \end{pmatrix} \right\| = 0$ ，因为 $\|x_2 - Z_2(1)\| > \|x_2 - Z_1(1)\|$ ，

所以 $x_2 \in Z_2(1)$ 。同样把所有的样本距离计算出来，划分为两类 $G_1(1) = (x_1, x_3)$ ， $G_2(1) = (x_2, x_4, x_5, \dots, x_{20})$ ；

(4) 根据新分成的两类建立新的聚类中心，

$Z_1(2) = \frac{1}{N_1} \sum_{x_i \in G_1(1)} x_i = \frac{1}{2}(x_1 + x_3) = (0, 0.5)^T$ ， $Z_2(2) =$

$\frac{1}{N_2} \sum_{x_i \in G_2(1)} x_i = \frac{1}{18}(x_2 + x_4 + x_5 + \dots + x_{20}) = (5.67, 5.33)^T$ ，如图 3 所示。

图 3 建立新聚类中心

(5) 若新旧聚类中心不相等，转至步骤(3)，更新聚类中心，直至新旧聚类中心相等，如图 4 所示。

图 4 最终聚类结果图

2 聚类分析故障识别模型建立

基于某公司离心式压缩机故障监测数据进行无

监督学习。如图 5 所示，选取不同故障信号作为训练样本，进行振动信号故障特征向量的提取和筛选，对筛选的故障特征值进行归一化处理和假数剔除，最后通过 K-means 聚类分析，实现故障模式识别。本文聚类分析故障识别模型算法通过 Matlab 编程实现。

图 5 故障识别 K-means 聚类分析方法流程图

2.1 机械设备故障敏感特征参数筛选

当机械设备出现故障时，机械元件损伤点在运行中反复撞击与之接触的其他元件表面，会产生振动冲击，可以直接采集到振动时域信号。本文没有选择相对复杂的时频域分析方法提取故障特征，而是通过数据驱动、统计分析，直接筛选敏感振动信号时域参数作为故障特征参数，开展聚类分析故障识别方法研究。

时域是指一个或多个信号其取值大小及相互关系等，可定义为很多不同的时间函数或参数，这些时间函数或参数的集合统称为时域参数^[14]。有效值即方均根值，是反映振动强度和能量的参数；峭度因子是反映偏离正态分布程度的参数，对冲击信号特别敏感，特别适用于表面损伤类故障，尤其是早期故障的诊断；峰值因子反映了峰值变化的程度，过大的峰值因子通常预示着存在局部缺陷；歪度因子反映了振动信号的非对称性，对磨损类故障较为敏感；裕度因子反映了信号的冲击程度。

选取某公司 C-301 型压缩机喘振故障信号样本数据、120-K-20012 型压缩机碰摩故障信号样本数据和 M-101 型压缩机不对中故障信号样本数据各 100 组，正常信号样本数据 25 组，每组数据 1 024 个点(以下同)。基于喘振、碰摩、不对中故障数据和正常数据进行时域分析，得到 4 种工况下振动数据的 5 种特征值，然后对每一个特征在不同工况下的值求出取值范围，如表 2 所示。

表 2 各工况下不同特征参数的取值范围

状态 特征量	正常		喘振	
	最小值	最大值	最小值	最大值
有效值	0.76	0.80	3.13	4.01
峭度因子	2.78	3.05	1.86	3.06
峰值因子	5.48	6.63	4.06	4.91
歪度因子	-0.32	-0.20	-0.19	0.49
裕度因子	8.82	10.92	5.12	7.74

状态 特征量	碰摩		不对中	
	最小值	最大值	最小值	最大值
有效值	5.28	14.23	6.33	12.27
峭度因子	1.46	1.54	1.99	3.80
峰值因子	2.91	3.18	3.66	5.16
歪度因子	0.04	0.08	0.57	1.18
裕度因子	3.48	3.80	4.71	7.50

如表 2 所示, 5 个时域特征参数在不同故障工况下的取值范围是不尽相同的, 所以各时域特征参量对离心压缩机不同故障的灵敏度是不一样的。本文用优、良、中、差来衡量各特征量对不同故障工况的灵敏度, 对正常数据与故障数据特征参量之间的差异做一个半定型分析。“差”为故障特征量和正常特征量范围大部分重合, 重合率大于 80%; “中”为故障特征量和正常特征量小部分重合, 重合率小于 20%; “良”为故障特征量和正常特征量范围不重合, 但不同故障特征量间范围大部分重合, 重合率大于 80%; “优”为故障特征量和正常特征量范围不重合, 但不同故障特征量间范围小部分重合, 重合率小于 20%^[15]。经过大量数据验证, 这样的特征量可以更好地用于 K-means 聚类算法的聚类过程, 结果如表 3 所示。

表 3 各特征参数对不同故障的灵敏度

特征参量	喘振	碰摩	不对中
有效值	优	良	优
峭度因子	差	优	差
峰值因子	良	优	良
歪度因子	良	优	优
裕度因子	良	优	良

从表 3 可知, 有效值和歪度因子对不同故障的灵敏度较高; 峭度因子灵敏度较差, 其中喘振故障和不对中故障的峰值因子重合率 100%, 裕度因子重合率 85%。选择有效值、歪度因子和裕度因子作为模型输入参数进行聚类分析。

2.2 数据归一化

由于直接提取的振动故障特征参数数值相差很大, 为防止聚类分析时突出大的特性指标排斥小的

特性指标, 必须对原始数据进行无量纲处理。本文采用极值归一化公式把数据压缩到[0, 1]之间, 形成诊断样本集的特征矢量矩阵

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

式中, x 为原始数据, x' 为归一化后数据, $x_{\min}$ 为原始数据最小值, $x_{\max}$ 为原始数据最大值。

2.3 剔除假数

在数据分析时, 假数对正确结果的影响比较大, 因此需要利用 3σ 准则剔除无效数据。 3σ 准则又称为拉依达准则, 它是先假设一组检测数据只含有随机误差, 根据计算得到的标准偏差 σ 确定区间 $(-3\sigma, 3\sigma)$, 认为凡超过这个区间的误差, 就不属于随机误差而是粗大误差, 含有该误差的数据应予以剔除。

设有数据 $x_1, x_2, \dots, x_n$, 算出其算术平均值 $\bar{x}$ 及剩余误差 $v_i = x_i - \bar{x}$ ($i=1, 2, \dots, n$), 该组数据的标准偏差为 σ , 假设 x_j 的剩余误差 v_j ($1 \leq j \leq n$) 满足 $|v_j| = |x_j - \bar{x}| > 3\sigma$, 则认为 x_j 是假数, 应予以剔除。

2.4 K-means 聚类分析

设定 $K=4$, 即将四类训练数据混合后, 通过 K-means 聚类分析模型的计算, 得到四个标准的聚类中心, 基于择近原则, 混合信号将会被聚为四类。

若四个聚类无重叠部分或重叠比例较小, 则认为实现良好的故障识别分类。

3 聚类分析故障识别模型验证

3.1 模型训练对比分析

基于××公司 C-301、120-K-20012 和 M-1010 型号离心压缩机故障数据开展无监督学习。C-301 型压缩机喘振故障信号样本、120-K-20012 型压缩机碰摩故障信号样本和 M-101 型压缩机不对中故障信号样本各 100 组, 正常信号 25 组, 三类故障信号数据和正常数据混合后作为训练样本, 筛选出有效值、歪度因子和裕度因子作为模型输入参数, 通过 K-means 聚类模型分出了四个类别, (有效值, 裕度因子, 歪度因子)作为类心坐标。如表 4 所示, 喘振故障信号样本里 100 组全部划分到了聚类 1 中; 碰摩故障信号样本里 100 组全部划分到了聚类 2 中, 不对中故障信号样本里 100 组全部划分到了聚类 3 中, 正常信号 25 组全部划分到了聚类 4 中。用圆点“g”代表聚类 1, 归为喘振故障, 类心坐标为 A(0.23, 0.34, 0.28); “+”代表聚类 2, 归为碰摩故障, 类心坐标为 B(0.44, 0.03, 0.25); “o”代表聚类 3,

归为不对中故障，类心坐标为 $C(0.60, 0.28, 0.77)$ ；“ ∇ ”代表聚类 4，归为正常信号，类心坐标为 $D(0.002, 0.84, 0.05)$ 。如图 6 所示，采用 K-means 聚类分析故障识别模型，正常和喘振、碰摩、不对中故障可以完全区分开。

表 4 喘振、碰摩和不对中故障训练组聚类结果

故障类型	聚类 1 数据量	聚类 2 数据量	聚类 3 数据量	聚类 4 数据量
喘振	100 组	0 组	0 组	0 组
碰摩	0 组	100 组	0 组	0 组
不对中	0 组	0 组	100 组	0 组
正常	0 组	0 组	0 组	25 组

图 6 正常、喘振、碰摩和不对中故障训练样本聚类分析图

抛弃有效值和歪度因子时，选择峭度因子、峰值因子和裕度因子作为模型输入参数进行聚类分析。如表 5 所示，喘振故障信号样本里有 68 组划分到了聚类 1 中，32 组划分到了聚类 3 中；不对中故障信号样本里有 41 组全部划分到了聚类 3 中，有 59 组划分到了聚类 1 中(图 7)。结果说明，选择峭度因子、峰值因子和裕度因子作为模型输入参数进行聚类分析时，喘振故障与不对中故障不能够区分开来，故障识别效果差。

表 5 喘振、碰摩和不对中故障训练组聚类结果

故障类型	聚类 1 数据量	聚类 2 数据量	聚类 3 数据量	聚类 4 数据量
喘振	68 组	0 组	32 组	0 组
碰摩	0 组	100 组	0 组	0 组
不对中	59 组	0 组	41 组	0 组
正常	0 组	0 组	0 组	25 组

对比分析得出结论，有效值、裕度因子和歪度因子是对离心压缩机故障更为敏感的时域特征参量，筛选为聚类分析故障识别模型输入参数更加合理。根据 K-means 聚类分析得到的喘振、碰摩、不对中和正常四种工况的聚类中心(A、B、C、D)，利用择近原则，开展故障模式自动识别。

图 7 峭度、峰值和裕度因子特征参量聚类分析图

3.2 模型验证

将 100 组 210-K-1650 型压缩机喘振故障信号数据作为验证数据并入训练样本中进行归一化处理，再根据择近原则对验证数据进行类别划分。计算归一化后的(有效值，裕度因子，歪度因子)的特征参量坐标，计算每组数特征参量坐标到各类心的距离。如表 6 所示，根据择近原则，距离哪类聚类中心近，验证组数据就自动划分到哪个聚类之中。统计分析 100 组验证数据中有 77 组距离类心 A 近，有 5 组距离类心 B 近，有 18 组距离类心 C 近，可得出结论：验证组的故障信号能够判断为喘振故障，准确率 77%。

表 6 喘振故障验证组距类心距离

验证数据	距类心 A 距离	距类心 B 距离	距类心 C 距离	距类心 D 距离
数据 1	0.30	0.58	0.51	0.65
数据 2	0.27	0.58	0.53	0.60
数据 3	0.25	0.59	0.59	0.54
...	...	...	...	...
数据 100	0.21	0.54	0.56	0.56

同理，将 120-K-20012 型压缩机另一组碰摩故障信号样本 100 组数据作为验证数据，计算每组数特征参量坐标到各类心的距离，如表 7 所示，统计分析 100 组验证数据全部距离类心 B 近。根据分析得出结论：验证组的故障数据能够判断为碰摩故障，准确率 100%。

表 7 碰摩故障验证组距类心距离

验证数据	距类心 A 距离	距类心 B 距离	距类心 C 距离	距类心 D 距离
数据 1	0.33	0.13	0.65	0.90
数据 2	0.33	0.19	0.65	0.90
数据 3	0.34	0.13	0.65	0.91
...	...	...	...	...
数据 100	0.31	0.13	0.64	0.88

将 M-101 型压缩机另一组不对中故障信号样本

100 组数据作为验证数据, 计算每组数特征参量坐标到各类心的距离, 如表 8 所示, 统计分析 100 组验证数据中有 87 组距离类心 C 近, 有 7 组距离类心 A 近, 有 6 组距离类心 B 近, 可得出结论: 验证组的故障信号能够判断为喘振故障, 准确率 87%。

表 8 不对中故障验证组距类心距离

验证数据	距类心 A 距离	距类心 B 距离	距类心 C 距离	距类心 D 距离
数据 1	0.46	0.57	0.22	0.87
数据 2	0.53	0.70	0.31	0.85
数据 3	0.44	0.62	0.35	0.77
...	...	...	...	...
数据 100	0.50	0.68	0.33	0.82

综上所述, 本文训练的聚类分析模型能够实现自动故障模式识别, 对于喘振故障识别准确率达到 77%, 对于碰摩故障识别准确率达到 100%, 对于不对中故障识别准确率达到 87%。

4 聚类分析与支持向量机故障识别方法对比验证

与聚类分析相似, 对于支持向量机故障识别方法, 利用 C-301 型压缩机喘振故障信号样本、120-K-20012 型压缩机碰摩故障信号样本和 M-101 型压缩机不对中故障信号样本各 100 组, 正常信号 25 组, 以筛选出的有效值、歪度因子和裕度因子作为特征参量, 将三类故障信号数据和正常数据混合后的训练样本作为支持向量机(SVM)的训练数据, 不同信号被标记为不同类别, 喘振为第一类, 碰摩为第二类, 不对中为第三类, 正常信号为第四类, 如图 8 所示。

图 8 SVM 故障训练样本分类

将 100 组喘振验证数据输入到 SVM 模型中进

行故障模式识别。如图 9 所示, 其中有 57 组被识别为喘振故障, 27 组被识别为碰摩故障, 16 组被识别为不对中故障, 识别准确率 57%。

图 9 SVM 喘振故障验证样本分类

将 100 组碰摩验证数据输入到 SVM 模型中进行故障模式识别。如图 10 所示, 其中 100 组全部被识别为碰摩故障。识别准确率 100%。

图 10 SVM 碰摩故障验证样本分类

将 100 组不对中验证数据输入到 SVM 模型中进行故障模式识别。如图 11 所示, 其中有 72 组被识别为不对中故障, 3 组被识别为喘振故障, 15 组被识别为碰摩故障, 识别准确率 72%。

图 11 SVM 不对中故障验证样本分类

对比分析得出,作为有监督学习的支持向量机,故障模式识别需要结合训练样本得到最优模型进行分类,而无监督学习的 K-means 聚类分析可以训练得到聚类中心,根据直观的距离判据能够自动识别故障模式,更加适用于工程应用;对于喘振和不对中故障的识别准确率,支持向量机方法明显低于 K-means 聚类分析方法。

5 结论

(1) 基于离心压缩机正常信号和喘振、碰摩、不对中故障信号监测数据训练学习,筛选出有效值、裕度因子和歪度因子振动信号时域参数作为聚类分析故障识别模型输入参数,其故障识别灵敏度优于峰值因子和峭度因子。

(2) 提出了包括机械设备故障敏感特征参数筛选、数据归一化、剔除假数、K-means 聚类分析的故障识别方法,构建了数据驱动的 K-means 聚类分析故障识别模型并与支持向量机故障识别准确性对比分析,验证了 K-means 聚类分析方法故障识别准确性优于支持向量机。

(3) 利用无监督学习 K-means 聚类分析训练得到离心压缩机正常、喘振、碰摩和不对中运行工况监测数据聚类中心,数据驱动方法计算特征参量坐标到各类心的直观距离,基于邻近原则实现故障模式自动识别,为实现故障诊断预测和智能决策,开展自愈调控提供了技术支撑。

参 考 文 献

- [1] 张明,冯坤,江志农. 基于动态自学习阈值和趋势滤波的机械故障智能预警方法[J]. 振动与冲击, 2014, 33(24): 8-14.
ZHANG Ming, FENG Kun, JIANG Zhinong. A mechanical fault early warning methodology based on dynamic self-learning threshold and trend filtering techniques [J]. Journal of Vibration and Shock, 2014, 33(24): 8-14.
- [2] 何勇,李增芳. 智能化故障诊断技术的研究与应用[J]. 浙江大学学报, 2003, 29(2): 119-124.
HE Yong, LI Zengfang. The research and application of intelligent fault diagnosis methods[J]. Journal of Zhejiang University, 2003, 29(2): 119-124.
- [3] 高金吉. 人工自愈与机器自愈调控系统[J]. 机械工程学报, 2018, 54(8): 83-94.
GAO Jinji. Artificial self-recovery and machinery self-recovery regulation system [J]. Journal of Mechanical Engineering, 2018, 54(8): 83-94.
- [4] 高金吉,王维民,何立东,等. 人工自愈与动力机械振动故障靶向抑制[J]. 北京化工大学学报, 2018, 45(05): 139-146.
GAO Jinji, WANG Weimin, HE Lidong, et al. Artificial self-recovery and target suppression of power machine vibration faults [J]. Journal of Beijing University of Chemical Technology, 2018, 45(5): 139-146.
- [5] 潘鑫,吴海琦,高金吉. 旋转机械气压液体式不平衡振动故障靶向自愈调控系统[J]. 机械工程学报, 2015, 51(1): 146-152.
PAN Xin, WU Haiqi, GAO Jinji. Rotating machinery targeting self-recovery regulation system for imbalance vibration fault with liquid-transfer active balancing device[J]. Journal of Mechanical Engineering, 2015, 51(1): 146-152.
- [6] 赵志宏. 基于振动信号的机械故障特征提取与诊断研究[D]. 北京: 北京交通大学, 2012.
ZHAO Zhihong. Research on vibration based machinery fault feature extraction and diagnosis [D]. Beijing: Beijing Jiaotong University, 2012.
- [7] 王峰. 化工过程非正常工况自愈调控理论及工程应用研究[D]. 北京: 北京化工大学, 2009.
WANG Feng. Study on abnormal situation self-recovery theory and engineering application for chemical process [D]. Beijing: Beijing University of Chemical Technology, 2009.
- [8] 安晶,艾萍,徐森,等. 一种基于一维卷积神经网络的旋转机械智能故障诊断方法[J]. 南京大学学报, 2019, 55(1): 133-142.
AN Jing, AI Ping, XU Sen, et al. An Intelligent fault diagnosis method for rotating machinery based on one dimensional convolution neural network [J]. Journal of Nanjing University, 2019, 55(1): 133-142.
- [9] 雷亚国,贾峰,孔德同,等. 大数据下机械智能故障诊断的机遇与挑战[J]. 机械工程学报, 2018, 54(5): 94-104.
LEI Yaguo, JIA Feng, KONG Detong, et al. Opportunities and challenges of machinery intelligent fault diagnosis in big data era [J]. Journal of Mechanical Engineering, 2018, 54(5): 94-104.
- [10] 马萍,张宏立,范文慧. 基于局部与全局结构保持算法的滚动轴承故障诊断[J]. 机械工程学报, 2017, 53(2): 20-25.

- MA Ping, ZHANG Hongli, FAN Wenhui. Fault diagnosis of rolling bearings based on local and global preserving embedding algorithm [J]. Journal of Mechanical Engineering, 2017, 53(2): 20-25.
- [11] BIN G F, GAO J J, LI X J, et al. Early fault diagnosis of rotating machinery based on wavelet packets: Empirical mode decomposition feature extraction and neural network [J]. Mechanical Systems and Signal Processing, 2012, 27: 696-711.
- [12] 袁胜发, 褚福磊. 支持向量机及其在机械故障诊断中的应用[J]. 振动与冲击, 2007, 36(11): 29-35.
- YUAN Shengfa, CHU Fulei. Support vector machines and its applications in machine fault diagnosis [J]. Journal of Vibration and Shock, 2007, 36(11): 29-35.
- [13] 刘鲲鹏, 苏涛, 赵磊, 等. 滚动轴承故障模式识别方法研究现状分析[J]. 内燃机与配件, 2018(23): 62-63.
- LIU Kunpeng, SU Tao, ZHAO Lei, et al. Analysis of Research Status of Rolling Bearing Fault Pattern Recognition Method[J], Internal Combustion Engine & Parts, 2018(23): 62-63.
- [14] 金盾, 柳小勤, 伍星. 一种基于冲击信号聚类分析的轴承故障诊断方法[J]. 机械与电子, 2011(12): 3-5.
- JIN Dun, LIU Xiaoqin, WU Xing. A method for bearing diagnosis based on clustering analysis of impact signals [J]. Machinery & Electronics, 2011(12): 3-5.
- [15] 李晓博, 江志农, 张沛, 等. 基于 IMS 聚类算法的柴油发动机故障诊断方法研究[J]. 振动与冲击, 2018, 37(7): 193-198, 246.
- LI Xiaobo, JIANG Zhinong, ZHANG Pei, et al. Fault diagnosis approach for diesel engines based on ims clustering algorithm [J]. Journal of Vibration and Shock, 2018, 37(7): 193-198, 246.
-
- 作者简介: 王庆锋, 男, 1972年出生, 博士, 副研究员。主要研究方向为设备动态监测、诊断与维护; 故障诊断与自愈; 在役再制造; 装置可靠性与风险评估。
- E-mail: wqf2422@163.com
- 刘家赫(通信作者), 男, 1995年出生。主要研究方向为故障诊断与健康管理。
- E-mail: liujiahebuct@163.com