

非完备先验知识下的滑动轴承摩擦状态识别

张峻宁¹, 张培林¹, 李 兵², 吴定海¹, 杨玉栋³

- (1. 军械工程学院 七系, 石家庄 050003;
2. 军械工程学院 四系, 石家庄 050003;
3. 武汉军械士官学校 四系, 武汉 430075)

摘 要: 针对监测系统通常无法全部获取轴承摩擦退化状态的先验知识,无法建立全摩擦状态的识别模型,从状态间的相似性出发,提出一种无先验知识下的基于灰色 B 型绝对关联度(AGRDB)和稀疏编码的滑动轴承状态识别方法。针对稀疏表示不具有监督性的缺陷,在稀疏编码的目标函数中引入 AGRDB 算法,训练类间距离最大、类内距离最小的正常润滑和严重摩擦的编码;在相同字典下建立具有一致判别性的稀疏表示模型,通过比较当前状态与正常润滑、严重摩擦的稀疏编码与重构误差,进一步识别当前轴承的状态,仿真信号和柴油机轴承实验的结果表明:所提方法能够在较少先验知识下识别出滑动轴承的早期摩擦状态(100~216 min)和严重摩擦状态(216~384 min),且算法简单,适合较少样本下的滑动轴承摩擦故障在线监测。

关 键 词: 非完备先验知识; 滑动轴承; 状态识别; 灰色 B 型绝对关联度 (AGRDB); 稀疏编码

中图分类号: V21; TH117.2 **文献标志码:** A

Plain bearing friction state recognition without complete prior knowledge

ZHANG Junning¹, ZHANG Peilin¹, LI Bing²,
WU Dinghai¹, YANG Yudong³

- (1. The 7th Department, Ordnance Engineering College, Shijiazhuang 050003, China;
2. The 4th Department, Ordnance Engineering College, Shijiazhuang 050003, China;
3. The 4th Department, Wuhan Institute of Ordnance Officer, Wuhan 430075, China)

Abstract: Given that the prior knowledge of all kinds of bearing friction degradation model cannot be attained usually, starting from the similarities of different states, a bearing friction fault's state recognition algorithm without prior knowledge was proposed based on sparse representation and absolute grey relational degree of B-mode (AGRDB). First, for the defects of sparse representation without supervision, the AGRDB was involved in the sparse representation, to get normal and severe friction codes under the largest distance between classes and smallest distance within the classes. Second, sparse representation model with discriminant sex was established under the same dictionary. And current state of the bearing was identified by comparing sparse coding and reconstruction error of normal lubrication and serious friction. Finally, the results of simulation signal and diesel engine

收稿日期:2016-06-01
基金项目:国家自然科学基金(51205405,51305454)
作者简介:张峻宁(1992—),男,硕士生,从事机械设备状态监测与故障诊断研究。
通讯作者:张培林(1955—),男,教授、博士生导师,博士,从事机械设备状态监测与故障诊断研究。

引用格式:张峻宁,张培林,李兵,等. 非完备先验知识下的滑动轴承摩擦状态识别[J]. 航空动力学报,2017,32(7):1704-1711.
ZHANG Junning,ZHANG Peilin,LI Bing,et al. Plain bearing friction state recognition without complete prior knowledge [J]. Journal of Aerospace Power,2017,32(7):1704-1711.

bearing experiment show that the proposed method can better identify the sliding bearing early friction state (100—216 min) and serious friction state (216—384 min) under the less prior knowledge. And this algorithm is suitable for plain bearing fault monitoring under less samples.

Key words: without complete prior knowledge; plain bearing; condition recognition; absolute grey relational degree of B-mode (AGRDB); sparse coding

滑动轴承是旋转机械的重要支撑部件,其运行状态好坏直接影响整个机械的性能,如何建立一个有效的评价模型识别滑动轴承的摩擦状态,对滑动轴承状态监测和故障诊断有十分重要的意义^[1]。目前常用的评价模型都需要滑动轴承不同摩擦状态的先验知识,将滑动轴承的状态监测转化为单一的模式识别问题^[2],而关于非完备先验知识下的滑动轴承状态识别的研究还未见报道。在实际设备运行中,由于受到噪声和其他激励源信号的影响,获取轴承各个摩擦状态的数据困难,导致完备先验知识下的滑动轴承状态识别模型建立困难,适应性不高,因此,如何在非完备先验知识下对滑动轴承摩擦状态识别将具有重要的学术和工程应用价值。

新轴承在经历短暂的磨合期后,进入较长时间的正常润滑状态,可知正常润滑的滑动轴承数据获取容易;当轴承处于严重摩擦时,轴瓦大面积的接触形成激烈的冲击和异响^[3],因此,也容易发现轴承的严重摩擦状态。为此,本文仅在正常和严重摩擦的先验知识下,提出一种滑动轴承的摩擦状态识别方法。

稀疏表示^[4]是通过自学习将信号表示成一组过完备基的线性组合,以实现对信号的简洁表达。经 Wright 等研究^[5],证明了稀疏表示还是一种适应性高,鲁棒性好的模式识别方法。近年来,稀疏表示的分类技术又被成功应用于故障诊断^[6-7]、人脸识别^[8]、图像分类^[9]等领域。稀疏表示广泛用于分类的独特优势是:①对非平稳信号具有极强的特征抽象能力,在模式识别中表现出优越性,适合非平稳、无重复信号的特征抽象;②一类稀疏表示的字典是由同类训练样本得到,再学习新模式的样本时,无需改变其他稀疏表示的字典,具有再学习的能力。因此稀疏表示适合不完备先验知识下的轴承状态监测。灰色 B 型绝对关联度 (AGRDB)是根据空间和局部结构计算两事物之间的关联性^[10]的方法,已广泛应用于工程领域,如人脸识别,导弹性能分析等。若将 AGRDB 应用到稀疏编码的相似性比较,就能够同时比较稀

疏编码的幅值、位置的关系。为此,本文仅在正常和严重摩擦先验知识下,提出一种基于稀疏表示和 AGRDB 的滑动轴承摩擦状态识别方法。首先,根据稀疏表示具有再学习的能力,尝试将正常润滑的特征字典作为状态评估模型的学习字典;其次,为了充分利用先验知识,在正常润滑和严重摩擦的稀疏表示模型中引入 AGRDB 的稀疏表示目标函数,通过训练正常润滑与严重摩擦的稀疏编码类间距离最大化、类内距离最小化,实现正常润滑与严重摩擦状态的判别性,最后将未知状态输入到稀疏表示模型,求解最大化靠近正常润滑和远离严重摩擦的稀疏编码,再比较当前状态与正常润滑和严重摩擦的稀疏编码差异,来识别当前轴承的摩擦状态,并及时对滑动轴承状态预警,最后通过仿真信号和柴油机滑动轴承实例,验证了本文所提方法的有效性。

1 非完备先验知识的稀疏编码识别模型

实际监测中,正常润滑的轴承数据和严重摩擦的数据容易获取,为此,本文提出仅在正常和严重摩擦故障数据下的基于 AGRDB 和稀疏表示的轴承状态评估。

1.1 先验知识下的稀疏训练模型

稀疏表示建模能力强,可通过稀疏编码衡量轴承不同摩擦状态的相似性,同一状态的相似性最高,因此,利用先验的数据建立稀疏训练模型,将正常润滑和严重摩擦的稀疏编码作为评价标准,比较其他状态与这两种已知状态的相似性。

$$\begin{aligned} \min \quad & \|a_z - D_z x_z\|^2 \\ \text{s. t.} \quad & \|\epsilon_z\|^2 < C, \quad \forall \quad i=1,2,\dots,K \end{aligned} \tag{1}$$

式中 a_z 为正常润滑的样本, D_z 为待求解的正常特征字典, x_z 为稀疏编码向量,其求解通过 (KS-VD)算法^[11-12]得到。同理可得严重摩擦的稀疏编码模型,见式(2)所示。

$$\begin{aligned} \min \quad & \|a_F - D_F x_F\|^2 \\ \text{s. t.} \quad & \|\epsilon_F\|^2 < C, \quad \forall \quad i=1,2,\dots,K \end{aligned} \tag{2}$$

式中 $\mathbf{a}_F$ 为严重摩擦的样本, $\mathbf{D}$ 为对应的学习字典。考虑到稀疏表示再学习新样本时, 无需改变其他稀疏表示的字典, 同时也为了方便比较不同状态在相同字典下的差异变化, 本文选取正常润滑的特征字典 $\mathbf{D}_Z$ 作为严重摩擦的学习字典。

1.2 基于 AGRDB 的稀疏编码训练模型

由于稀疏表示是无监督的数据降维方法, 无法将类别信息融入到稀疏编码中, 因此, 仅仅通过式(1)和式(2), 并不能对其他摩擦故障状态识别。为此, 本文在稀疏表示的目标函数中引入 AGRDB, 建立有监督的稀疏编码模型, 使得到的正常润滑和严重摩擦的稀疏编码具有分类性, 并将其定义为轴承摩擦发展的两边界编码。

设有两个需要判别的向量 $\mathbf{X}_i$ 和 $\mathbf{X}_k$, 则灰色 B 型绝对关联度定义如下:

$$G = \frac{1}{1 + \frac{1}{n} \Delta D + \frac{1}{n-1} \cdot \Delta V + \frac{1}{n-2} \cdot \Delta A} \quad (3)$$

式中距离差为

$$\Delta D = \sum_{j=1}^n |\mathbf{X}_i(j) - \mathbf{X}_k(j)| \quad (4)$$

$$\Delta V =$$

$$\sum_{j=1}^{n-1} |\mathbf{X}_i(j+1) - \mathbf{X}_k(j+1) - \mathbf{X}_i(j) - \mathbf{X}_k(j)| \quad (5)$$

$$\Delta A = \frac{1}{2} \sum_{j=2}^{n-1} |[\mathbf{X}_i(j+1) - \mathbf{X}_k(j+1)] - 2[\mathbf{X}_i(j) - \mathbf{X}_k(j)] + [\mathbf{X}_i(j-1) - \mathbf{X}_k(j-1)]| \quad (6)$$

则引入 AGRDB 的边界编码求解为

$$\begin{cases} \min \|\mathbf{a}_Z - \mathbf{D}_Z \mathbf{x}_Z\|^2 + \lambda S_B(\mathbf{x}_Z, \bar{\mathbf{x}}_F) \\ \min \|\mathbf{a}_F - \mathbf{D}_Z \mathbf{x}_F\|^2 + \lambda S_B(\mathbf{x}_F, \bar{\mathbf{x}}_Z) \\ \text{s. t. } \|\varepsilon_i\|^2 < C, \quad \forall i=1, 2, \dots, K \end{cases} \quad (7)$$

式中

$$S_B(\mathbf{x}_Z, \bar{\mathbf{x}}_F) = \frac{1}{N_Z} \sum_{l \in x_l} G(\mathbf{x}_Z^l, \bar{\mathbf{x}}_F)$$

$$S_B(\mathbf{x}_F, \bar{\mathbf{x}}_Z) = \frac{1}{N_F} \sum_{l \in x_l} G(\mathbf{x}_F^l, \bar{\mathbf{x}}_Z)$$

式中 $\mathbf{a}_Z$ 为正常润滑的样本; $\mathbf{a}_F$ 为严重摩擦的样本; $\mathbf{D}_Z$ 为正常特征字典; $\mathbf{x}_Z, \mathbf{x}_F$ 为正常润滑和严重摩擦的稀疏编码; $\bar{\mathbf{x}}_Z, \bar{\mathbf{x}}_F$ 为正常和严重摩擦稀疏编码的均值; $S_B(\mathbf{x}_Z, \bar{\mathbf{x}}_F)$ 目的是通过增加正常润滑与严重摩擦的稀疏编码的类间距离, 提高两边界状态的判别性。 $S_B(\mathbf{x}_Z, \bar{\mathbf{x}}_F)$ 和 $S_B(\mathbf{x}_F, \bar{\mathbf{x}}_Z)$ 越

小则说明正常与严重摩擦的稀疏编码距离越大, 越容易区分。若同时求取 $\mathbf{x}_F$ 和 $\mathbf{x}_Z$, 则将式(7)转化为非凸问题, 求解困难且稳定不高, 为此, 本文依次更新 $\mathbf{x}_F$ 和 $\mathbf{x}_Z$, 反复迭代求解直至收敛, 许多实验也验证了这种方式的有效性。

因此, 本文将类间距离最大化、类内距离最小化正常润滑与严重摩擦的稀疏编码定义为轴承摩擦状态发展的两边界, 为下一步轴承微弱摩擦状态(介于正常润滑和严重摩擦之间的微弱摩擦状态)的识别提供了评价标准。又因为经过稀疏编码判别, 得到的重构误差也具有判别性, 为此, 结合这两种判据的优势, 定义轴承正常润滑的状态指标

$$e_Z = \|\mathbf{a}_Z - \mathbf{D}_Z \mathbf{x}_Z\|_2^2 + \lambda S_B(\mathbf{x}_F, \mathbf{x}_Z) \quad (8)$$

式中第 1 项为在正常字典下的样本重构误差, 第 2 项为测试状态的稀疏编码与正常稀疏编码均值的 AGRDB 值, λ 为权重系数。同理可得严重摩擦状态指标, 见式(9)所示。

$$e_{\max} = \|\mathbf{a}_F - \mathbf{D}_Z \mathbf{x}_F\|_2^2 + \lambda S_B(\mathbf{x}_F, \mathbf{x}_Z) \quad (9)$$

1.3 无完备先验知识下的轴承摩擦状态评估

为了使稀疏编码间接反映轴承不同摩擦状态一致性发展规律。在定义的正常润滑与严重摩擦的稀疏编码基础上, 在先验知识建立的稀疏表示模型中加入有监督的稀疏编码, 使得当前状态的编码最大化靠近正常润滑编码和远离严重摩擦的编码, 再根据测试样本的稀疏编码评估当前状态, 设定稀疏编码判别模型

$$\begin{aligned} \min \|\mathbf{a}_f - \mathbf{D}_Z \mathbf{x}_f^l\|^2 + \lambda S_G(\mathbf{x}_f^l, \mathbf{x}_Z, \mathbf{x}_F) \\ \text{s. t. } \|\varepsilon_i\|^2 < C, \quad \forall i=1, 2, \dots, K \end{aligned} \quad (10)$$

式中 $\mathbf{a}_f$ 为待评估的轴承样本, $\mathbf{D}_Z$ 为正常特征字典, $\mathbf{x}_f^l$ 为待评估的第 l 个样本的稀疏编码向量, $S_G(\mathbf{x}_f^l, \mathbf{x}_Z, \mathbf{x}_F)$ 的目的是获得最靠近正常编码和远离严重摩擦编码的测试样本稀疏编码。

$$S_G(\mathbf{x}_f^l, \bar{\mathbf{x}}_Z, \bar{\mathbf{x}}_F) = \frac{S_B(\mathbf{x}_f^l, \bar{\mathbf{x}}_Z, \bar{\mathbf{x}}_F)}{S_W(\mathbf{x}_f^l, \bar{\mathbf{x}}_Z)} \quad (11)$$

$$S_B(\mathbf{x}_f^l, \bar{\mathbf{x}}_Z, \bar{\mathbf{x}}_F) = G(\bar{\mathbf{x}}_Z, \bar{\mathbf{x}}_F) + \min G(\mathbf{x}_f^l, \bar{\mathbf{x}}_F) \quad (12)$$

$$S_W(\mathbf{x}_f^l, \bar{\mathbf{x}}_Z) = \frac{1}{N_f} \sum_{l \in x_f} G(\mathbf{x}_f^l, \bar{\mathbf{x}}_Z) \quad (13)$$

式中 $\bar{\mathbf{x}}_Z, \bar{\mathbf{x}}_F$ 分别为正常类和严重摩擦类的稀疏编码向量均值; N_f 为待评估的故障样本数目; $S_W(\mathbf{x}_f^l, \bar{\mathbf{x}}_Z)$ 为测试样本与正常状态的相似性评价标准, $S_W(\mathbf{x}_f^l, \bar{\mathbf{x}}_Z)$ 越大则说明与正常状态的相似性越大, 越接近于正常状态; $S_B(\mathbf{x}_f^l, \bar{\mathbf{x}}_Z, \bar{\mathbf{x}}_F)$ 为测试样本与严重摩擦的差异性评价标准, $S_B(\mathbf{x}_f^l,$

$\bar{\mathbf{x}}_Z, \bar{\mathbf{x}}_F)$ 越小则说明样本与严重摩擦状态的差异越大。

再定义轴承的当前状态指标。

$$e_u = \|\mathbf{a}_f - \mathbf{D}_Z \mathbf{x}_f^l\|_2^2 + \lambda S_G(\mathbf{x}_f^l, \mathbf{x}_Z, \mathbf{x}_F) \quad (14)$$

因此,式(14)是通过比较待测试样本与正常润滑的变化相似性,和与严重摩擦的差异来实现非完备先验知识下的轴承摩擦状态识别,又因为滑动轴承摩擦故障发展大致随时间成递增趋势的特点,为方便滑动轴承摩擦状态监测,定义性能退化率公式如下:

$$E_u = \frac{e_u - e_Z}{e_{\max} - e_Z} \quad (15)$$

分析式(15)知, E_u 是用来描述轴承当前摩擦状态相对于正常润滑状态的差异程度,当 $E_u \approx 0$, 表明轴承当前的状态越接近于正常润滑,当 $E_u \approx 1$, 表明轴承摩擦严重,接近于完全损坏状态。由

此可见,在轴承摩擦故障的退化阶段,性能退化率的概率分布也不相同。因此,可根据退化率的概率分布设定预警阈值。当正常状态的性能退化率达到一定量时,通过计算其均值获得黄色预警值,如果监测的性能指标都在上下预警阈值之间,则表明该轴承处于正常润滑状态,如果性能指标有多次超过预警线,则表明轴承处于边界摩擦故障状态,同理可计算得到严重摩擦预警阈值(红色预警阈值)。

由此得到非完备先验知识下的滑动轴承摩擦状态评估系统,见图 1 所示。

具体算法如下:

1) 特征提取。机械设备中滑动轴承的摩擦状态变化,都会直接引起声发射(AE)信号的时频域特征发生变化^[13]。为此,本文选取常用的时频域特征:最大值 y_q 、最小值 y_p 、峰峰值 y_a 、方差 y_r 、




图 1 滑动轴承摩擦状态评估系统

Fig.1 Flow chart of the plain bearing friction condition assessment system

偏斜度 y_s 、峭度 y_k 、方均根 y_{crms} 、灰色关联度 y_g 等 9 个时域特征,和小波包 3 层分解^[14] 的 8 个频带信号的能量值,以及声发射常用特征:事件计数 y_o ,最终组成滑动轴承摩擦故障的监测特征样本 $\mathbf{a}$ 。另外,为了消除时频域特征的不同量纲关系,对特征向量归一化处理。

2) 模型训练。选择合适的参数,将正常润滑的样本 $\mathbf{A}_Z=[\mathbf{a}_Z^1,\mathbf{a}_Z^2,\cdots,\mathbf{a}_Z^l]$ 带入到式(1)通过 KSVD 求解特征字典 $\mathbf{D}_Z$,再将正常和严重摩擦的样本 $\mathbf{A}_Z=[\mathbf{a}_Z^1,\mathbf{a}_Z^2,\cdots,\mathbf{a}_Z^l],\mathbf{A}_F=[\mathbf{a}_F^1,\mathbf{a}_F^2,\cdots,\mathbf{a}_F^l]$ 带入到基于 AGRDB 的边界稀疏编码模型中,得到轴承正常和严重摩擦的状态指标 $e_Z,e_{\max}$,并将其定义为轴承摩擦发展的两边界。

3) 状态评估。将待评估的轴承监测样本 $\mathbf{A}_f=[\mathbf{a}_f^1,\mathbf{a}_f^2,\cdots,\mathbf{a}_f^l]$ 代入到稀疏表示识别模型中,计算测试样本的稀疏编码向量 $\mathbf{x}_f$ 和重构误差项,并按照式(14)和式(15)得到轴承当前状态的性能退化率 E_u ,同时判断当前退化状态是否超过警戒阈值,若超过则根据相应预警信息指定维修计划,若没有,则继续监测下一个样本。

由于轴承的摩擦是一个渐变的过程,本文假设性能退化率是随摩擦逐渐递增的趋势,如果假设成立,该指标就可以反映轴承的摩擦状态;若不成立,也可以将该指标 E_u 与 0,1 比较,判断是否严重摩擦并及时报警,下面利用实验对该假设验证。

2 仿真分析

采用仿真信号验证本文所提方法对摩擦状态的识别性,仿真信号设定为

$$\mathbf{x}(t)=\mathbf{s}_1(t)+\mathbf{s}_2(t)+\mathbf{z} \tag{16}$$

式中 $\mathbf{s}_1(t)=2t\cdot e^{-50t}\cdot \sin(2\pi\cdot 64t)$ 为模拟故障声发射信号, $\mathbf{s}_2(t)=0.05\sin(2\pi\cdot 10t)+\sin(2\pi\cdot 5t)$ 为本底信号, $\mathbf{z}$ 为噪声。幅值 $2t$ 为模拟故障随时间的逐渐加深的过程。

为了分析噪声对信号状态监测的影响,在仿真信号中添加不同程度的白噪声,图 2 是噪声为 10 dB 的仿真信号。

仿真信号的采样频率为 5 kHz,采样点数为 40014,为了模拟滑动轴承从正常到故障的退化过程,将信号按顺序分为 30 段,采样点数为 1480,再利用本文所提方法对其分析,评估结果见图 3 所示。

分析图 3 可知,随着故障程度的加深,性能退化曲线逐渐增大。在故障初期,性能退化曲线变




图 2 仿真信号时域波形图

Fig. 2 Time domain waveform of simulated signal




图 3 仿真信号的摩擦状态评估

Fig. 3 Friction condition assessment of simulation signals

化平缓,这与设定的仿真信号幅值 $2t$ 紧密相关,再从不同噪声强度的退化曲线分析,可知噪声强度越大,性能退化率幅值越低,但都是随故障程度加深而逐渐增大,由此表明本文所提的故障状态评估方法能够很好的识别故障退化过程,且具有较好的抗噪性能。

3 应用实例

3.1 实验过程

实验在西南交通大学柴油机实验台上进行,实验装置为 S195-2 型柴油机,实验轴承是柴油机输出端的主轴承(铝锡 20 铜-钢双金属板轴承),将 RNT-200 型声发射传感器放置于轴承盖上部平面,并以 500 kHz 频率监测轴承的工况。为了模拟滑动轴承的摩擦故障实验,在实验中对柴油机润滑油路改进,封死原轴承供油油路,引入一个截止阀的单独控制油路,当柴油机正常运行至 100 min 后,关闭单向阀、切断供油油路,通过切断润滑油油路模拟轴承摩擦过程,直至轴承冒黑烟(此时轴承已损坏),具体实验系统示意图见图 4 所示。

工程中常用有效值和峰峰值监测设备退化的过程^[15],见图 5 所示。由图 5 知,整个监测曲线区分不明显,无法准确识别轴承正常、边界摩擦,严重摩擦的状态,因此,利用常用特征监测轴承的摩擦状态效果不佳。




图 4 滑动轴承实验系统示意图

Fig. 4 Diagram of plain bearing experimental system




图 5 轴承摩擦过程中时域特征值的变化

Fig. 5 Change of time domain value in bearing friction process

3.2 模型训练

将 20 个正常润滑的样本和 20 个严重摩擦故障样本用于稀疏编码识别模型的训练。首先将正常润滑的特征带入稀疏编码模型中,通过 KSVD 算法得到正常特征字典,其中 KSVD 的参数设置如下:滑动窗口为 24×1 ,滑动步长为 1,字典原子数为 20,稀疏度为 12,训练原子数目为 400。

再将正常和严重摩擦故障的样本带入式(7),确定轴承摩擦发展的两边界状态:正常稀疏编码、严重摩擦稀疏编码。图 6 是正常润滑与严重摩擦的稀疏编码图。由图 6 知,正常润滑特征的稀疏编码稀疏度为 0.95,主要存在于 A 区域和 C 区域,而严重摩擦状态的稀疏编码稀疏度为 1.05,且主要存在于 B 区域。由此证明,经过本文所提的稀疏编码模型,能够很好的实现严重摩擦故障与正常润滑的区分。

3.3 状态监测与结果分析

将待测试的样本带入到稀疏编码识别模型中,得到该样本的稀疏编码向量。为了验证获得的稀疏编码具有识别性,再通过核模糊聚类方法




图 6 稀疏编码分布图

Fig. 6 Sparse coding pattern

(KFCM)^[16]对全部稀疏编码聚类,选择聚类数为 3,高斯核函数为 15,加权指数为 2。图 7 是经 KFCM 聚类的三维效果,由图可知,稀疏编码在没有先验知识得背景下,将测试样本分为 3 类,且是按照时间顺序分布,大致反应滑动轴承从正常润滑到严重摩擦的发展过程,由此证明了经过本文所提方法学习的稀疏编码具有判别性,因此,可用于滑动轴承摩擦状态的监测与识别。

再将全部样本的稀疏编码和重构误差带入到性能退化率公式,得到轴承摩擦故障发展曲线,见图 8 所示。由图 8 可知,轴承的摩擦故障发展大致分为两个阶段,第 1 个阶段是出现在第 100 min 左右,性能退化率幅值开始增大,并出现了跃变现象,正好与实验在第 100 min 切断润滑油油路的时间顺序一致,表明轴承在切断油路后,轴瓦开始产生点接触式摩擦,逐渐形成边界摩擦,第 2 个阶

段是在第 216 min,性能退化率出现剧烈增大和跃变,表明此时轴承已经出现大面积接触摩擦,形成了严重的摩擦故障。分析整条曲线先平稳后跃变、先缓后急的发展趋势,正好符合轴瓦摩擦的规律^[17-18],初期的轴瓦凹凸点接触,又趋于润滑,逐步往复发展成点对面、面对面的接触式摩擦状态。因此,相比于图 5 中的均方根和峰峰值指标,本文所提的状态评估指标,更能够准确描述和识别轴承的边界摩擦和严重摩擦状态。

为了实时监测滑动轴承的运行状况并及时预警,利用性能退化率的概率分布设定状态预警警戒线,见图 9 所示。




图 7 稀疏编码聚类效果图

Fig. 7 Effect of sparse coding clustering






图 8 滑动轴承摩擦状态的监测曲线


Fig. 8 Friction condition monitoring curve of plain bearing



(a) 滑动轴承摩擦状态的监测预警



(b) A区域局部放大图



(c) B区域局部放大图

图 9 滑动轴承摩擦故障的预警发布

Fig. 9 Warning issued of the plain bearing friction fault

由图 9 可知,预警线将轴承的摩擦故障发展主要分为 3 个阶段:第 1 阶段为 0~100min 内,轴承处于正常润滑状态;第 2 阶段为 100~216 min 内,轴承开始出现边界摩擦故障,因此设立黄色预警线,及时维修轴承;第 3 阶段为 216~384 min 内,轴承出现严重摩擦故障,因此设定红色预警线,需要立即停止设备,更换已损坏的滑动轴承。

4 结 论

本文建立了非完备先验知识下基于 AGRDB 和稀疏表示的状态识别模型,解决了滑动轴承各摩擦状态数据获取困难,无法有效建立全摩擦状态识别模型的问题。

1) 在计算稀疏编码的目标函数中引入 AGRDB,通过增强最大化类间距离确定正常与严重摩擦故障的稀疏编码,提高了稀疏编码的分类能力。

2) 采用性能退化率比较与正常和严重摩擦的差异,以估计测试样本的状态。仿真信号和实例应用表明,所提方法训练样本少,更够更加准确监测滑动轴承正常润滑、边界摩擦、严重摩擦的状态。

参考文献:

[1] 秦萍,阎兵,谭达明. 利用声发射诊断滑动轴承接触摩擦故障的研究[J]. 西南交通大学学报, 2001, 36(3): 272-275.
QIN Ping, YAN Bing, TAN Daming. Study on fault diagnosis of sliding bearings using ae signals[J]. Journal of Southwest Jiaotong University, 2001, 36(3): 272-275. (in

- Chinese)
- [2] 俞啸,丁恩杰,陈春旭,等.基于HHT和有监督稀疏编码的滚动轴承故障状态识别方法[J].煤炭学报,2015,40(11):2587-2595.
- YU Xiao,DING Enjie,CHEN Chunxu,et al. Rolling bearing fault state recognition method based on HHT and supervised sparse coding[J]. Journal of China Coal Society, 2015,40(11):2587-2595. (in Chinese)
- [3] 孙丹,张楚,郭瑞,等.基于两相流理论滑动轴承动力特性求解[J].航空动力学报,2012,27(12):2822-2828.
- SUN Dan,ZHANG Chu,GUO Rui,et al. Solution of dynamic characteristics of journal bearing based on two phase flow theory[J]. Journal of Aerospace Power, 2012, 27(12):2822-2828. (in Chinese)
- [4] OLSHAUSEN B A. Emergence of simple-cell receptive field properties by learning a sparse code for natural images[J]. Nature,1996,381(6583):607-609.
- [5] WRIGHT J,YANG A Y,GANESH A,et al. Robust face recognition via sparse representation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2009, 31(2):210-227.
- [6] 朱启兵,杨宝,黄敏.基于核映射稀疏表示分类的轴承故障诊断[J].振动与冲击,2013,32(11):30-35.
- ZHU Qibing,YANG Bao,HUANG Min. Bearing fault diagnosis based on a kernel-mapping sparse representation classification[J]. Journal of Vibration and Shock,2013,32(11):30-35. (in Chinese)
- [7] 王海涛,谢寿生,武卫,等.基于稀疏最小二乘支持向量机的航空发动机动态过程辨识[J].航空动力学报,2010,25(9):2140-2146.
- WANG Haitao,XIE Shousheng,WU Wei,et al. Dynamic process identification of aircraft engine based on a novel sparse least square support vector machines[J]. Journal of Aerospace Power,2010,25(9):2140-2146. (in Chinese)
- [8] 郭业才,张铃华.统一化的LGBP特征及稀疏表示的人脸识别算法[J].计算机辅助设计与图形学学报,2015,27(3):400-406.
- GUO Yecai,ZHANG Linghua. Face recognition algorithm based on uniform LGBP and SRC[J]. Journal of Computer-Aided Design and Computer Graphics,2015,27(3):400-406. (in Chinese)
- [9] CHEN Y,NASRABADI N M,TRAN T D. Sparse representation for target detection in hyperspectral imagery[J]. Journal of Selected Topics in Signal Processing, 2011,5(3):629-640.
- [10] 邵晓刚.基于矩阵灰色B型绝对关联度的人脸检测算法研究[D].长春:东北师范大学,2012.
- SHAO Xiaogang. The research of the face detection algorithm taking matrix absolute grey relational degree of B-mode as core[D]. Changchun:Northeast Normal University,2012. (in Chinese)
- [11] ELAD M,ABARON M. Image denoising via sparse and redundant representations over learned dictionaries[J]. IEEE Transactions on Image Processing,2006,15(12):3736-3745.
- [12] AHARON M,ELAD M,BRUCKSTEIN A,et al. KSVD: an algorithm for designing of overcomplete dictionaries for sparse representation[J]. IEEE Transactions on Signal Processing,2006,54(11):4315-4320.
- [13] 傅和品,秦萍.滑动轴承故障诊断方法的实用性分析研究[J].轻工机械,2006,24(4):97-98.
- FU Hepin,QIN Ping. The study of fault diagnosis method on slide bearing[J]. Light Industry Machinery, 2006, 24(4):97-98. (in Chinese)
- [14] 荆双喜,吴鑫涛,华伟.基于小波包频带能量特征提取的低速重载滑动轴承诊断研究[J].煤矿机械,2007,28(9):191-193.
- JING Shuangxi,WU Xintao,HUA Wei. Plain bearing fault diagnose based on detecting technology of wavelet packet frequency band energy[J]. Coal Mine Machinery,2007,28(9):191-193. (in Chinese)
- [15] 胡瑾秋,张来斌,胡春艳,等.基于一数据自组织挖掘的机械设备状态退化预警方法[J].中国石油大学学报,2014,38(3):142-150.
- HU Jinqiu,ZHANG Laibin,HU Chunyan,et al. An early warning method of degradation for mechanical facilities based on data self-organization mining technology[J]. Journal of China University of Petroleum, 2014, 38(3):142-150. (in Chinese)
- [16] CHAN T,VESE L. Active contours without edges[J]. IEEE Transactions on Image Processing,2001,10(2):266-277.
- [17] 张峻宁,张培林,陈彦龙,等.基于摩擦信号的滑动轴承接触摩擦故障的状态监测[J].振动与冲击,2016,35(3):68-73.
- ZHANG Junning,ZHANG Peilin,CHEN Yanlong,et al. Condition monitoring of contacting fault of plain bearings based on friction signals[J]. Journal of Vibration and Shock,2016,35(3):68-73. (in Chinese)
- [18] 向丹,岑健.基于EMD熵特征融合的滚动轴承故障诊断方法[J].航空动力学报,2015,35(5):1149-1156.
- XIANG Dan,CEN Jian. Method of roller bearing fault diagnosis based on feature fusion of EMD entropy[J]. Journal of Aerospace Power,2015,35(5):1149-1156. (in Chinese)

(编辑:叶青)