

引入稀疏原子特征融合的滑动轴承摩擦故障状态监测

张峻宁¹, 张培林¹, 华春蓉², 李 兵¹, 陈彦龙¹

(1. 军械工程学院 车辆与电气工程系, 石家庄 050003;

2. 西南交通大学 机械工程学院, 成都 610031)

摘 要: 从信息融合理论出发,将特征的稀疏表达作为特征融合参数,提出一种结合 K 奇异值分解(KSVD)和最大相关最小冗余准则(mRMR)的轴承摩擦故障特征融合算法。该算法采用 KSVD 对信号稀疏化,将稀疏系数对应的字典原子作为特征融合的参数,用以表达非线性故障信息;针对字典原子集的优化选择问题,基于互信息的 mRMR 提出一种确定最优原子集的原子数目的准则;最后,通过最大化原则融合稀疏系数,提取故障状态监测的有效信息。轴承摩擦故障模拟实验的结果表明,所提方法能够更好地融合不同特征的故障信息,相比于单特征和其他融合特征方法,提高了约 12% 的故障识别率。

关 键 词: 滑动轴承; 状态监测; 信息融合; 稀疏表示; 字典原子; 互信息

中图分类号: V229.2; TH117.2

文献标志码: A

Condition monitoring of friction fault of plain bearings by introducing sparse atoms feature fusion

ZHANG Junning¹, ZHANG Peilin¹, HUA Chunrong²,
LI Bing¹, CHEN Yanlong¹

(1. Department of Vehicle and Electric Engineering,
Ordnance Engineering College, Shijiazhuang 050003, China;

2. School of Mechanical Engineering,
Southwest Jiaotong University, Chengdu 610031, China)

Abstract: Starting from the theory of information fusion, a algorithm of bearing friction fault feature fusion was proposed based on K-means singular value decomposition (KSVD) and maximum relevance minimum redundancy (mRMR) principle. First, in order to represent the nonlinear fault information, the algorithm uses KSVD to sparse the signals, and the dictionary atoms corresponding to the sparse coefficients were used as the parameters of the feature fusion. Second, in order to optimize the selection of dictionary atomic set, a criterion based on mutual information mRMR was proposed to determine the number of atoms in the optimal atomic set. Finally, the sparse coefficients were fused by maximizing the principle to extract the valid information for fault condition monitoring. The results of simulation experi-

收稿日期: 2016-04-13

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,主要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,主要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,华春蓉,等. 引入稀疏原子特征融合的滑动轴承摩擦故障状态监测[J]. 航空动力学报, 2017, 32(10): 2476-2483. ZHANG Junning, ZHANG Peilin, HUA Chunrong, et al. Condition monitoring of friction fault of plain bearings by introducing sparse atoms feature fusion[J]. Journal of Aerospace Power, 2017, 32(10): 2476-2483.

ment of bearing friction fault show that the proposed method can better integrate the feature information of the redundancy and complementarity. Compared with the single feature and other fusion method, the proposed method can improve fault recognition rate about 12%.

Key words: plain bearing; condition monitoring; information fusion; sparse representation; dictionary atom; mutual information

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,如何有效利用声发射(AE)信号分析滑动轴承故障,提取能反映轴承摩擦故障的普遍适用特征量,对滑动轴承状态监测和故障诊断有十分重要的意义^[1]。

常用的监测特征参数有:时域特征、频域特征、AE 特征参数(事件计数、振铃计数)等,但是这些指标都不具有足够的一致性和敏感性^[2],或者对微弱故障不敏感,或者缺乏较为一致的趋势,因此,单一的特征参数监测滑动轴承的摩擦故障,难以克服信号的多变性和故障特征的非线性,从而描述滑动轴承的摩擦状态困难。信号的稀疏性受到越来越多的关注,稀疏表示被广泛应用到信号处理中,例如信号和图像去噪、人脸识别、压缩传感、盲源分离等领域^[3]、Candes^[4]提出信号自身或在某种变换域下具有稀疏性。Aharon 等^[5]指出信号特征可以由较少的系数精确地表示。K 奇异值分解(KSVD)是稀疏分解中的一种重要方法,因能够产生与训练特征高度适应的冗余字典,对信号具有较好的稀疏表达而受到广泛关注。YANG Bin 等^[6]提出了将 KSVD 字典稀疏表达的图像融合算法。余南南等^[7]利用 KSVD 字典对脑部的医学图像进行融合。上述实例都表明基于 KSVD 的字典稀疏融合对信号具有非常好的稀疏表达能力,能够更好地实现特征融合。为筛选字典原子中与故障诊断无关的信息,文献[8]提出最大相关最小冗余原则(mRMR)的特征选择方法,依靠统计学原则选择特征,有效筛选了无效信息,降低了特征维数,提高了故障识别率。

为此,本文尝试从特征稀疏性的角度出发,提出了一种 KSVD 稀疏表示和 mRMR 优化准则的特征融合算法(KSVD-RMR)来融合轴承 AE 信号的特征参数,以此监测轴承摩擦故障的全过程。首先,针对故障特征的非线性和 AE 信号的多变性,利用“滑动窗”技术,将不同特征的曲线分段,基于 KSVD 得到不同特征曲线在冗余字典下的稀疏系数,再将该系数对应的字典原子作为原始特征融合的参数。为了从字典原子中筛选出与故障信息无关的原子,再针对字典原子集的优化选

择问题,结合 mRMR 算法评价字典原子,利用最佳原子数目准则选择信息互补的字典原子,并最大化融合稀疏系数,最后根据选择的字典和融合的系数得出全新的特征曲线。实验结果表明,所提算法在主观视觉和客观指标方面,都比常用的融合算法更好地区分轴承在不同摩擦阶段的故障,具有更好的故障诊断效果。

1 算 法

1.1 KSVD 字典学习算法

KSVD 字典^[9]是稀疏表示的一种算法,能够产生与训练样本高度适应的冗余字典,对信号具有非常好的稀疏表达能力。设训练样本矩阵为 $Y=[y_i]_{i=1}^n$,冗余字典为 $D \in \mathbf{R}^{s \times K} (K \gg n)$,稀疏编码系数为 $X=[x_i]_{i=1}^n$,伪范数 $\|a\|_0$ 表示系数非零项的上限, ζ 为求解误差上限,则 KSVD 模型被定义为

$$\begin{aligned} \hat{a} &= \operatorname{argmin}_a \|a\|_0 \\ \text{s. t. } \|Y - DX\|_2^2 &\leq \zeta \end{aligned} \tag{1}$$

步骤 1 初始化字典。如定义基于离散余弦变换(DCT)字典。

步骤 2 系数编码。运用正交匹配追踪算法(OMP)^[10]求解每一块列向量 $b_i Y$ 的稀疏编码向量 x_i

$$x_i = f_{\text{omp}}(D_i, b_i Y, \zeta) \tag{2}$$

步骤 3 字典学习。逐步更新字典原子 d_l

$$\|Y - Dx_i\|^2 = \left\| \left(Y - \sum_{j \neq l} d_j x_j^T \right) - d_l x_l^T \right\|^2 = \|E_l - d_l x_l^T\|^2 \tag{3}$$

式中 x_l^T 是编码系数集 X 中第 l 行系数; E_l 是代表抽取字典 D_l 后的误差矩阵。定义 σ 为 $N \times \delta(l)$ 阶矩阵,且在矩阵中 $(\delta_l(v), v)$ 的元素全部为 1,其余全部为 0。定义向量 $x_k^l(v) = x_l^T(v) \sigma$ 和矩阵 $E_k^l = E_l \sigma$ 分别为 x_l^T 和 E_l 去掉零元素后的收缩效果,对 E_k^l 做奇异值分解, $E_k^l = U \Delta V^T$,将字典中的第 k 列更新为 U 的第 1 列, x_l^T 更新为 V 的第 1 列与 $\Delta(1,1)$ 的乘积。

步骤 4 根据设定的迭代次数更新原子,最

终得到冗余字典 D 。

1.2 mRMR 原则的特征选取

mRMR 的主要思想是利用互信息选择特征参数与目标空间的相关性和特征之间的冗余性。

设随机变量 z 和 ∂ 的概率密度为 $p(z)$ 和 $p(\partial)$, 联合概率密度为 $p(z, \partial)$, 则其互信息为

$$r(z, \partial) = \iint p(z, \partial) \lg \frac{p(z, \partial)}{p(z)p(\partial)} dzd\partial \quad (4)$$

再利用互信息可得 mRMR 准则:

$$\max C(L, \alpha), \quad C = \frac{1}{|L|} \sum_{z_i \in S} r(z_i, \alpha) \quad (5)$$

$$\min R(L), \quad R = \frac{1}{|L|^2} \sum_{z_i, z_j \in S} r(z_i, z_j) \quad (6)$$

式中 $|L|$ 是特征空间维数, $r(z_i, \alpha)$ 是子空间 L 中特征 z_i 与目标类别 α 之间的互信息, $r(z_i, z_j)$ 是特征 z_i 与特征 z_j 之间的互信息。

综合考虑上述两个准则就是 mRMR 算法, 并定义为 mRMR 优化准则, 即

$$\max \Phi(C, R), \quad \Phi(C, R) = C - R \quad (7)$$

对于上式的求解, 一般采用前向 Greedy 搜索算法^[11]实现。假设 Z 是原始特征集, S_{m-1} 是已经选择的 $m-1$ 个特征集合, 则特征选择的目的是从剩下的原始特征集中 $\{Z - S_{m-1}\}$ 中选择第 m 个特征, 且该特征需满足下式:

$$\max_{z_j \in Z - S_{m-1}} \left[r(z_j, \alpha) - \frac{1}{m-1} \sum_{z_i \in S_{m-1}} r(z_j, z_i) \right] \quad (8)$$

2 基于 KSVD 和 mRMR 的特征信息融合

2.1 特征提取

特征信息融合旨在将原始高维特征的互补信息融合到较少特征中, 并尽可能地保留有利于故障诊断信息的融合方法^[12]。因此, 准确并完整地提取原始特征信息是一个十分重要的步骤。基于 KSVD 对信号具有十分好的稀疏表达能力, 能够挖掘深层次的特征信息, 本文将不同特征曲线的稀疏系数作为特征信息融合的线索, 将稀疏系数对应字典原子作为特征融合的参数, 克服了原始特征的非线性和 AE 信号的多变性。考虑到稀疏表示是一种基于整个数据的全局性操作, 本文首先将每个特征按监测的时间顺序连成一条曲线, 代表轴承从正常到故障损坏的全过程数据, 然后为了更好地融合不同特征的显著性信息, 再采用“滑动窗”技术(类似放大镜), 对特征曲线进行局部分块, 将分块的特征向量作为此时的特征, 同时

还可以保证稀疏的移不变特性。

首先, 将等间隔采集的原始特征 y_1 按照从轴承正常到轴承摩擦故障的顺序连成一条特征曲线 $I_1 \in \mathbf{R}^N$, 再选择步长为 1 的滑动窗对特征曲线 $I_1 \in \mathbf{R}^N$ 按照窗口大小为 $w \times 1$ 的尺寸进行列向量划分, 并将全部列向量 $v_i (i = 1, 2, 3, \dots, N - w + 1)$ 组成矩阵 $V_1 \in \mathbf{R}^{w \times (N - w + 1)}$, 同理可得其他 $n-1$ 个特征曲线对应的矩阵, 最终组成联合矩阵 $V = [V_1 \ V_2 \ \dots \ V_n]$, 再通过 KSVD 算法训练得到冗余字典 $D = [d_1, d_2, \dots, d_K]$, 利用 OMP 求解联合矩阵 V 的稀疏编码系数 $X = [X_1 \ X_2 \ \dots \ X_n]$, 最后以稀疏系数为线索, 寻找对应的字典原子, 并将其作为特征融合的参数。

2.2 融合算法

由于不同的原子之间存在着非线性和冗余, 有必要对字典原子筛选和稀疏系数融合, 实现特征信息的有效利用。设 $I_1, I_2, \dots, I_n$ 为原始特征, $I_1 = \theta + C_1, I_2 = \theta + C_2, \dots, I_n = \theta + C_n$, 其中 θ 是特征 $I_1, I_2, \dots, I_n$ 共同的特征, $C_1, C_2, \dots, C_n$ 是各自的特征, 设 $v_{1i}, v_{2i}, x_{1i}, x_{2i}$ 分别为 V_1, V_2, X_1, X_2 的第 i 列向量

$$v_{1i} = D x_{1i} = D \begin{bmatrix} x_{1i}^{\theta} \\ 0 \\ 0 \\ \vdots \\ x_{1i}^c \\ 0 \end{bmatrix}; \quad v_{2i} = D x_{2i} = D \begin{bmatrix} x_{2i}^{\theta} \\ 0 \\ 0 \\ \vdots \\ 0 \\ x_{2i}^c \end{bmatrix} \quad (9)$$

式中 x_{1i}^{θ} 和 x_{2i}^{θ} 是 x_{1i}, x_{2i} 中相同位置的稀疏编码值, 对应字典中相同的原子 d_i^{θ} , 代表 v_{1i}, v_{2i} 的共同特征, x_{1i}^c, x_{2i}^c 是 x_{1i}, x_{2i} 中不同位置的稀疏编码值, 分别对应字典中不同的原子 d_i^c , 代表 v_{1i}, v_{2i} 各自的特征, 而编码值的大小则代表该特征的强弱。本文特征融合是希望能够最大程度选择对故障状态监测有用的字典原子, 充分利用字典原子的有效信息, 提高对故障状态监测的精度。因此, 通过 mRMR 选择稀疏系数对应的字典原子, 通过最大化原则融合稀疏系数。考虑到 mRMR 只能选择最优字典原子集合: $S_1 < S_2 < \dots < S_k$, 无法确定最优字典原子子集的原子数目的缺陷, 为此, 本文再提出一种最优原子数目原则, 以求融合后特征对故障诊断正确率最高且原子数目最少, 本文采用最小二乘支持向量机 (LS-SVM)^[13] 作为分类器, 令

$$\max(R_{S_i}), \quad R_{S_i} = \frac{p(S_i) \times 100\%}{\omega \times s_i} \quad (10)$$

式中 $p(S_i)$ 表示在原子集合 S_i 下的监测精度, s_i 表示字典原子子集 S_i 的原子数目, ω 是原子数目的权重, ω 越小, 表示故障状态监测的正确率起主要作用, ω 越大, 表示原子数目所占比重越大。

图 1 是本文所提的 KSVD-RMR 融合算法流程图, 具体算法如下:

1) 特征提取。按照 3.1 节所述, 采用滑动窗技术处理特征曲线, 通过 KSVD 得到冗余字典 D 和稀疏系数 X 。再针对第 i 列样本 v_i , 按照式(9)中的稀疏系数为线索, 寻找对应的字典原子, 其中 D^θ 是共同特征的原子集合, D^c 是各自特征的特征原子集合。

2) 最优原子选择。利用 mRMR 算法选择最优原子子集, 令 S 是已选择的字典原子集合, F 是待选的字典原子集合; 令 $S=\{\}$, $F=\{D^\theta, D^c\}$ 。再分别计算 D^θ 中字典原子与目标类别 α 的相关

性, 选择 $\max(I(d_i, \alpha))$ 最大的一个字典原子作为 d_i^h , 令 $S_i=\{d_i^h\}$, $F_i=\{D^c, D^\theta-d_i^h\}$; 并依据最优原子数目原则确定原子数目 L , 选择剩余 $L-1$ 个原子; for $m=2:L$, 设 $d_i \in S_{m-1}$, $d_j \in F_{m-1}$, 按照式(8)选择 F_{m-1} 中最大信息的字典原子 d_i^h , 令 $S_m=\{S_{m-1}+d_i^h\}$, $F_m=\{F_{m-1}-d_i^h\}$, 结束。同此法, 再求取字典 D^c 的最优原子集。

3) 融合特征。为了最大程度融合对故障监测有用的信息, 采用绝对值最大原则融合被选择的原子的对应系数, 见式(11)所示。最终得到样本第 i 列向量的最优字典原子集和融合系数。

$$x_i^\theta = \arg \max_{k=1,2,\dots,n} (|x_{ki}^\theta|) \quad (11)$$

4) 特征曲线重构。融合的特征矩阵则可以由 $V_f=S_m X_f$ 计算得到, 再按照滑动窗逆变换重构, 得到融合后的特征曲线, 即: 将特征矩阵 V_f 的向量 v_i 放置于特征曲线对应位置处, 通过平均法得到最终的融合结果。




图 1 KSVD-RMR 算法流程图

Fig. 1 Flow chart of KSVD-RMR algorithm

3 应用实例

为了验证 KSVD-RMR 算法的有效性, 对静载荷滑动轴承摩擦故障实验数据进行分析。

实验在西南交通大学静载荷滑动轴承实验台上进行, 实验轴承为剖分式 S-195 型柴油机主轴承, 在该轴承下部加载 30 N·m 的砝码模拟轴承载荷, 通过切断润滑油油路模拟滑动轴承摩擦故障, 实验中轴承两端通过 6010 滚动轴承支撑, 旋转动力经电动机——无级变速箱——弹性联轴节输出, RNT-200 型的 AE 传感器放置于轴承盖上部平面, 以 500 kHz 频率采集 AE 信号, 同时将热电偶穿过轴承盖瓦孔测量轴承温度, 再在轴与轴瓦之间构造测量电路图, 作为判断轴承是否出现故障的依

据, 实验系统如图 2 所示, 实验测量电路见图 3。

图 3 中 Ω_1 为油膜电阻, Ω_2 为平衡电阻, 当轴与瓦未接触时(液体润滑状态), Ω_1 电阻趋近于无穷, 此时电路不通, 灯泡未亮; 当轴与瓦之间完全接触时, Ω_1 电阻几乎为零, 灯泡呈现亮光状态, 因




图 2 滑动轴承实验系统示意图

Fig. 2 Diagram of plain bearing experimental system




图 3 滑动轴承状态判断测量电路

Fig. 3 Measurement circuit of plain bearing state

此将测量电压 U 作为判断滑动轴承故障的依据。

实验时,当主轴转速稳定后,切断轴瓦的供油,以每隔 2 min 采集 AE 信号,直至轴承温度急剧升高,转速下降,此时停止实验。选取轴承不同程度摩擦故障(正常润滑、边界摩擦、严重摩擦)的样本 112 个,其中正常润滑样本 38 个,边界摩擦样本 37 个,严重摩擦样本 37 个,再分别选取前 10 个作为训练样本,剩下的作为测试样本。

3.1 特征参数提取

设 $y(i), i=1, 2, 3, \dots, M$ 是实验采集的时序信号,计算实验信号的最大值 y_q 、最小值 y_p 、峰峰值 y_a 、方差 y_r 、偏斜度 y_s 、峭度 y_k 、冲击信号均方根 y_{crms} 、摩擦信号均方根 y_{mrms} ^[14]、事件计数 y_o 、灰色关联度 y_g 并归一化,然后将这 10 个对轴承摩擦故障敏感的特征参数作为轴承摩擦故障状态监测的原始特征集^[15],表 1 给出了部分原始特征

值。由表 1 可知,单一的特征都只能表现一部分故障特性,因此,依靠单一特征诊断轴承摩擦故障具有缺陷。

3.2 基于 KSVD-RMR 的特征信息融合

根据 2.3 节所述的方法,利用 KSVD-RMR 对原始特征集融合,算法参数设置为:滑动窗口的长×宽为 6×1 ,滑动步长为 1,字典原子数为 100,稀疏度设为 30,随机选择字典原子数目为 16,具体融合特征结果见图 4 所示,其中图 4(a)是部分原始特征曲线,图 4(b)融合后曲线。从视觉效果来看,融合后的特征曲线变化更稳定、更平滑,相比于原始特征,融合后的特征更容易区分正常润滑、边界摩擦、严重摩擦的状态,再利用 LS-SVM 对融合的结果进行故障分类,见图 5 所示,同时给出了不同字典原子子集的分类性能。

由图 5 可知,原子数为 13 时,轴承摩擦状态监测正确率为 88.40%,当原子数为 17 时,故障监测正确率达到最高 91.48%,此后随着原子数的增加,故障监测正确率降低,因此,并不是所有稀疏系数对应的原子都对故障监测有效,相反还会造成故障监测的精度下降,有必要从中选择最优的原子子集,提高轴承摩擦状态监测的速度和精度。

本文虽然通过 mRMR 能够选择分类性好且冗余关联小的字典原子,但是原子数目的确定则

表 1 不同摩擦状态的部分原始特征参数
Table 1 Part of original feature parameters extracted from the different friction condiction signals

摩擦状态	序号	特征参数									
		y_q	y_p	y_f	y_{crms}	y_{mrms}	y_g	y_o	y_s	y_k	y_r
正常润滑	1	2.12	-2.68	5.79	0.08	0.04	0.993	304	-0.0002	0.010	0.009
	2	2.032	-1.86	3.89	0.06	0.03	0.994	194	0	0.004	0.006
	3	2.41	-2.56	4.97	0.08	0.03	0.993	241	-0.0007	0.010	0.008
	4	2.30	-4.21	8.57	0.11	0.04	0.992	410	-0.0006	0.057	0.017
边界摩擦	1	2.68	-3.52	7.20	0.09	0.05	0.992	398	0.0001	0.08	0.014
	2	2.27	-2.82	5.09	0.10	0.03	0.988	435	-0.0016	0.019	0.014
	3	3.26	-3.82	7.08	0.10	0.04	0.991	439	-0.0012	0.028	0.015
	4	3.42	-4.23	7.67	0.10	0.04	0.991	438	-0.0019	0.046	0.016
严重摩擦	1	4.09	-5.63	9.72	0.19	0.08	0.977	1041	-0.0154	0.180	0.053
	2	4.61	-7.07	11.69	0.29	0.10	0.948	2305	-0.0364	0.517	0.113
	3	4.05	-5.24	9.29	0.24	0.09	0.961	1803	-0.0230	0.298	0.080
	4	3.89	-5.26	9.24	0.28	0.09	0.951	2077	-0.0250	0.407	0.101




图 4 基于 KSVD-RMR 融合前后的特征曲线对比
Fig. 4 Comparison of feature curves before and after KSVD-RMR fusion

是本文需要解决的另外一个问题。利用最优原子数目原则确定原子的个数,其中选择权重 $w=1, 2, 3, 4, 5$, 得到适应度 R_{S_i} 随字典原子的变化, 见图 6 所示。

分析图 6 可知,随着 w 权重的减小,适应度 R_{S_i} 逐渐降低,且特征数目越大,下降越大,直至特征数目为 18 时,适应度 R_{S_i} 才基本保持不变,但是在曲线中都存在一个极值点,综合分析,选择极值点 $S_i=13$ 作为本文选择的字典原子数目。图

7 是本文选择字典原子前后的原子示意图。由图可知,原始系数对应的字典原子,原子分布散乱,原子维数高,而优化选择后的字典原子,不仅维数降低,而且原子更加集中,各层系数分布更加均匀,反映了本文选择的原子的优势。




图 5 不同原子数目的分类正确率
Fig. 5 Classification accuracy rate of different atomic numbers




图 6 不同原子数目的适应度曲线
Fig. 6 Fitness curves of different atomic numbers

3.3 状态监测结果分析

根据选取的最佳字典原子,利用 KSVD-RMR 对原始特征集融合,再经 LS-SVM 分类器进行摩擦故障监测,见表 2 所示,同时给出单一特征的诊断结果。

由表 2 可知,单一特征都只是对某种摩擦状态敏感,如事件计数特征对正常润滑状态敏感,AE 信号最大值对严重摩擦状态敏感等,而本文融合的特征则能够较好地监测全部轴承摩擦状态,其中正常润滑监测准确率为 92.86%,严重摩擦状态结果次之,准确率为 88.89%,边界摩擦监测精度最低,结果为 77.78%。分析轴承摩擦故障机理可知,轴承在处于边界摩擦状态时,存在多种摩擦作用形式^[16],包括有油膜与轴颈的摩擦、润滑油与轴瓦的摩擦和轴与瓦的干摩擦等,其本身就与轴承正常润滑和严重摩擦状态有相似的特征,因此监测边界摩擦状态困难,需要融合更多的

有效特征,以进一步监测轴承边界摩擦故障。另外,为了验证文本算法的优势和有效性,再与主元分析(PCA)、局部保持投影算法(LPP)、改进半监督局部保持投影(ISS-LPP)等算法^[17-18]比较,见表3所示。




图 7 优化选择的字典原子示意图

Fig. 7 Optimal selection of dictionary atoms

表 2 单一特征的摩擦状态监测结果

Table 2 Friction condition monitoring results based on single feature

特征量	监测结果准确率/%		
	正常润滑	边界摩擦	严重摩擦
y_q	63.33	37.03	85.18
y_p	57.14	14.81	62.50
y_{crms}	32.14	51.85	40.74
y_a	46.42	25.93	62.96
y_{mrms}	42.86	0	40.74
y_g	50.00	51.85	82.14
y_o	75.00	48.15	85.18
y_s	50.00	14.81	48.14
y_k	42.86	0	55.56
y_r	53.57	11.11	74.07
KSVD-RMR	92.86	77.78	88.89

表 3 不同融合算法的摩擦状态监测结果

Table 3 Friction condition monitoring results based on different fusion algorithms

融合方法	监测结果准确率/%			分类精度/%
	正常润滑	边界摩擦	严重摩擦	
无	64.28	59.26	77.78	67.11
PCA	71.42	62.96	77.78	70.72
LPP	82.14	70.37	81.48	77.99
ISS-LPP	85.71	74.07	85.71	81.83
KSVD-RMR	92.86	77.78	88.89	86.51

由表3可见,直接采用原始高维特征集监测摩擦故障效果不佳,表明原始特征集中大量的冗余信息降低了轴承的监测精度;PCA是基于协方差的融合方法,没有考虑特征的几何结构,无法完整提取原始特征的信息,因此融合的特征存在缺陷,监测效果一般;LPP、ISS-LPP属于流行学习方法,将高维空间的低维故障流行应用到低维的特征空间中,降低了特征间的冗余性,提高了监测效果,但是由于轴承摩擦故障复杂,很难将所有摩擦故障对应到一个故障流形中,而本文算法通过训练与特征曲线高度一样的冗余字典,能够深层次的挖掘特征信息,再通过mRMR选择稀疏的字典原子和融合系数,就能够更好去除特征间的冗余性,相对于其他算法,所提算法融合的特征状态监测正确率最高,由此说明KSVD-RMR算法的有效性。

4 结 论

本文提出的KSVD-RMR滑动轴承特征融合算法充分结合了稀疏表示和mRMR选择准则,计算出稳定性更强的故障特征,提高了故障监测的精度,为滑动轴承摩擦故障状态监测提供了一条新的途径。

- 1) 将KSVD获得的稀疏系数对应的原子作为特征融合的参数,再基于互信息的mRMR选择最优的故障字典原子,能够更好地获取了故障特征信息。
- 2) 建立了最优字典原子数原则,确定了故障监测正确率最高且字典原子数最少的原子集,提高了故障监测的速度和效率。

3) 相比于常用的特征融合算法,本文算法结合了KSVD对信号稀疏表达的优势,能够更好融合轴承AE信号的故障特征信息,更容易监测滑

动轴承正常润滑、边界摩擦、严重摩擦的状态。

参考文献:

[1] 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)

[2] 章立军,刘博,张彬,等. 基于时频图像融合的轴承性能退化特征提取方法[J]. 机械工程学报,2013,49(22):54-58.
ZHANG Lijun,LIU Bo,ZHANG Bin,et al. Feature extraction method of bearing performance degradation based on time-frequency image fusion[J]. Journal of Mechanical Engineering,2013,49(22):54-58. (in Chinese)

[3] 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)

[4] CANDES E J. Compressive sampling[C]// Proceedings of International Congress of Mathematics. Madrid, Spain; the European Mathematical Society,2006:1433-1452.

[5] 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.

[6] YANG Bin,LI Shutao. Multifocus image fusion and restoration with sparse representation[J]. IEEE Transactions on Instrumentation and Measurement,2010,59(4):884-892.

[7] 余南南,邱天爽,毕峰,等. 基于 K-SVD 的医学图像特征提取和融合[J]. 大连理工大学学报,2012,52(4):605-610.
YU Nannan,QIU Tianshuang,BI Feng,et al. Medical image features extraction and fusion based on K-SVD[J]. Journal of Dalian University of Technology,2012,52(4):605-610. (in Chinese)

[8] PENG Hanchuan, LONG Fuhui, DING C. Feature selection based on mutual information: criteria of max-dependency, max-relevance, and min-redundancy[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2005,27(8):1226-1238.

[9] 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.

[10] OLSHAUSEN B A, FIELD D J. Sparse coding of sensory

inputs[J]. Current Opinion in Neurobiology,2004,14(4):481-487.

[11] 李兵,张培林,任国全,等. 基于互信息的滚动轴承故障特征选择方法[J]. 测试技术学报,2009,23(2):184-190.
LI Bing,ZHANG Peilin,REN Guoquan,et al. Features selection for rolling bearing fault diagnosis based on mutual information[J]. Journal of Test and Measurement Technology,2009,23(2):184-190. (in Chinese)

[12] 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,2015,30(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,2015,30(5):1149-1156. (in Chinese)

[13] 刘金刚,王登峰,何霞辉,等. 基于 LS-SVM 模型的无级变速器夹紧力控制系统故障诊断[J]. 汽车工程,2009,30(4):318-323.
LIU Jingang,WANG Dengfeng,HE Xiahui,et al. Fault diagnosis of CVTC lamping force control system based on least squares support vector machine model[J]. Automotive Engineering,2009,30(4):318-323. (in Chinese)

[14] 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)

[15] 张乾. 基于振动信号的轴承状态监测和故障诊断方法研究[D]. 湖南:中南大学,2012.

[16] 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)

[17] 邵良杉,张宇. 基于小波理论的支持向量机瓦斯涌出量的预测[J]. 煤炭学报,2011,36(1):104-107.
SHAO Liangshan,ZHANG Yu. Mine gas gushing forecasting based on wavelet theory support vector machine[J]. Journal of China Coal Society,2011,36(1):104-107. (in Chinese)

[18] 杨望灿,张培林,吴定海,等. 基于改进半监督局部保持投影算法的故障诊断[J]. 中南大学学报,2015,46(6):2060-2066.
YANG Wangcan,ZHANG Peilin,WU Dinghai,et al. Fault diagnosis based on improved semi-supervised locality preserving projections[J]. Journal of Central South University,2015,46(6):2060-2066. (in Chinese)