

基于流行-IMF 奇异值熵的转子故障特征提取方法^{*}

孙泽金， 赵荣珍
(兰州理工大学机电工程学院 兰州, 730050)

摘要 针对转子振动信号的非平稳性以及微弱故障特征难以提取的问题,提出一种基于集合经验模式分解(ensemble empirical mode decomposition,简称 EEMD)的奇异值熵和流形学习算法相结合的故障特征提取方法。首先,对原始振动信号进行 EEMD 分解,得到若干本征模态函数(intrinsic mode function,简称 IMF)分量,根据峭度-欧式距离评价指标选取故障信息丰富的敏感分量,组成初始特征向量,求其奇异值熵;其次,利用近邻概率距离拉普拉斯特征映射算法(nearby probability distance Laplacian eigenmap,简称 NPDLE)对奇异值熵组成的特征矩阵进行降维处理;最后,将得到的低维特征子集输入到 K-近邻(K-nearest neighbor,简称 KNN)中进行模式辨识。用一个双跨度转子实验台数据集和 Iris 仿真数据集对所提方法进行了验证,结果表明,IMF 奇异值熵和 NPDLE 相结合的方法可以有效地实现转子故障特征提取,提高了故障辨识的准确性。

关键词 特征提取; 集合经验模态分解; 本征模态函数; 奇异值熵; 近邻概率距离拉普拉斯特征映射算法
中图分类号 TP17; TH166

引 言

当转子发生故障时,其振动信号多表现为非线性、非平稳特性,因而难以有效提取信号中的特征进行故障诊断^[1]。多通道提取振动特征信息的诊断模式在转子故障诊断方面具有较强优势,然而该模式在获得有效信息的同时还将引入大量的非敏感、冗余特征。因此,如何更好地提取低维敏感特征子集已成为故障诊断的一个重要研究方向^[2]。

经验模态分解^[3](empirical mode decomposition,简称 EMD)可以自适应地将非线性、非平稳信号分解成若干本征模态分量。但 EMD 存在着端点效应和模态混叠问题^[4]。为了抑制模式混叠,Wu 等^[5]在 EMD 方法的基础上引入噪声辅助分析,提出集合经验模式分解(EEMD),能够很好地还原信号的本质,是对 EMD 算法的重大改进,可有效抑制模态混叠现象。EEMD 分解产生的本征模态分量包含原始信号的故障特征信息,为量化这些故障特征,引入奇异值熵^[6]。奇异值熵可以用来衡量矩阵的稳定性,它的大小反映了转子系统运行状态的差别,可以作为描述转子系统的工作状态和故障类型

的特征量,被广泛应用于设备信号处理中。虽然奇异值熵在机械信号分析等多方面有优势^[7],但是往往采样信号中会混入多余的无用信息,为后续的模式识别造成了一定的难度。因此,需要寻找有效的降维方法,去除冗余与干扰信息,提取出易于辨识不同故障类别的本质特征。

拉普拉斯特征映射(Laplacian eigenmap,简称 LE)算法^[8]是一种有效的局部保持流形学习算法,在高维数据的非线性特征挖掘中,显示出良好的效果。LE 算法通常运用欧式距离这一测度去构建局部邻域与权重,但在实际中,欧式距离有时并不能准确表示数据点间的关系,其原因在于欧式距离仅表示样本点间的直线距离,即假设样本点的重要性相同且互不相关。如文献^[9]所述,欧式距离不能对数据点间的相似程度进行准确的描述,可能同类数据点间的欧式距离大于非同类数据点间的欧式距离,导致在近邻点选择时出现误差。随机近邻嵌入(stochastic neighbor embedding,简称 SNE)算法^[10]中采用一种概率的表达形式代替欧式距离来表示数据点间的关系,根据两数据点间的概率判断是否近邻,这更利于近邻点的选择。

综上分析,笔者在 LE 算法基础上引入近邻概

^{*} 国家自然科学基金资助项目(51675253);兰州理工大学红柳一流学科建设资助项目
收稿日期:2018-12-11;修回日期:2019-04-04

率距离(nearby probability distance,简称 NPD),提出一种 IMF 奇异值熵和 NPDLE 相结合的特征提取方法,并利用 KNN 算法对转子故障进行分类,为转子故障诊断提供一种新的参考途径。

1 相关原理简介

1.1 EEMD 算法简介

EEMD 能够根据信号自身的特点,自适应地将非线性、非平稳的多模态信号分解为若干个平稳单一模态的 IMF 分量和一个余项^[5]。该方法利用高斯白噪声解决了 EMD 算法中模态混叠的缺陷。具体步骤^[11]如下:

1) 在原始信号 $x(t)$ 中加入均值为零、标准差为常数的高斯白噪声 $n_i(t)$, 即

$$x_i(t) = x(t) + n_i(t) \tag{1}$$

2) 对 $x_i(t)$ 进行 EMD 分解,得到 N 个 IMF 记为 $a_{ij}(t)$, $j=1\sim N$,余项表示为 $r_i(t)$;

3) 将步骤 2 所得的 IMF 进行平均运算,平均后得到的 IMF 为

$$a_j(t) = \frac{1}{M} \sum_{i=1}^M a_{ij}(t) \tag{2}$$

其中: $a_j(t)$ 为原始信号进行 EEMD 分解后所得的第 j 个 IMF 分量。

1.2 奇异值熵

奇异值是矩阵固有的特征^[12],如果矩阵中的元素发生改变时,奇异值也会发生变化,因此可用来描述转子系统运动状态的变化,文献^[13]给出奇异值熵的定义如下。

1) 在奇异值理论中,任意 $m \times n$ 阶矩阵 G 的奇异值分解为

$$G = USV^T \tag{3}$$

其中: U 和 V 分别为 $m \times m$ 阶和 $n \times n$ 阶正交阵; $S = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_n)$ 为对角阵,其对角元素为 G 的奇异值,并按降序排列。

2) 对式(3)中 S 的奇异值序列进行平方运算处理,可得到 $\sigma_1^2, \sigma_2^2, \dots, \sigma_n^2$ 。每个分量进行归一化处理,即

$$E_i = \frac{\sigma_i^2}{E} \quad (i = 1, 2, \dots, n) \tag{4}$$

其中: $E = \sigma_1^2 + \sigma_2^2 + \dots + \sigma_n^2$, 有 $\sum_{i=1}^n E_i = 1$, 满足信息熵的归一化条件。

3) 根据信息熵算法的定义,可得奇异值熵的计算公式为

$$H = - \sum_{i=1}^n E_i \ln E_i \tag{5}$$

1.3 LE 原理介绍

LE 算法降维的实质就是寻找到一个平均意义上保持数据点局部邻近信息,即在原来高维特征空间中邻近的点映射到低维空间后也应该邻近。以两点间的加权距离作为损失函数,利用图拉普拉斯算子的谱性质进行求解,求出能够保持数据集局部信息的最优低维表示^[14-15]。LE 算法步骤如下。

1) 构建近邻图,可采用 ϵ -或 K 近邻法。

2) 确定边的权值 W_{ij} 。常用来确定 W_{ij} 的方法有:①热核方法,若第 i 和第 j 个结点之间是连接的,则有 $W_{i,j} = \exp(-\frac{\|x_i - x_j\|^2}{\sigma^2})$, 否则 $W_{ij} = 0$; ②直接法,如果第 i 和第 j 个节点之间有边连接,则 $W_{i,j} = 1$, 否则 $W_{i,j} = 0$ 。

3) 特征映射。假设前面所建立的邻接图是连通的,通过计算广义特征向量获得低维嵌入坐标,即对式(6)求解广义特征值

$$L_y = \lambda D_y \tag{6}$$

其中: D 为对角权值矩阵,且 $D_{ii} = \sum_j W_{ji}$; L 为近邻图上的拉普拉斯算子, $L = D - W$ 。

最小化式(7)所示目标函数

$$\Phi_{\text{lap}}(Y) = \sum_{i=1}^N \sum_{j \neq i} \frac{1}{2} \|y_i - y_j\|^2 W_{ij} = \text{tr}(Y^T L Y) \tag{7}$$

最终得到 d 维嵌入坐标 Y ,即为 L 的第 2 个到第 $d+1$ 个特征值对应的特征向量。LE 算法把问题转化为了特征值的求解,不需要迭代值的计算,所以只需要很少的计算量。

2 NPDLE 算法的构建

传统的 LE 算法利用欧式距离来进行构建局部近邻与权重时,可能导致近邻的选取不准确,这是因为同类故障样本点间的欧式距离可能比非同类数据点间的距离更大。SNE^[10]与传统的数据降维方法不同,它在欧式距离的基础上提出了一种概率距离来描述数据样本点的远近程度,把样本点间的欧式距离转化为概率表达形式,是一种基于数据间相似度的降维方法。参考 SNE 算法,本研究将近邻概率

距离这一度量引入 LE 算法中。

2.1 近邻概率距离

在 SNE 中,点 x_i 选择 x_j 作为近邻的概率为 P_{ij}

$$P_{ij} = \frac{\exp\left(-\frac{\|x_i - x_j\|^2}{2\lambda^2}\right)}{\sum_{k \neq i} \exp\left(-\frac{\|x_i - x_k\|^2}{2\lambda^2}\right)} \quad (8)$$

其中: P_{ij} 为点 x_j 在以点 x_i 为中心的高斯分布中的概率密度。

参数 λ 是以高维空间样本点 x_i 为中心的高斯方差,它的确定与最终确定的近邻数量有关系。考虑到以 x_i 为中心点的高斯分布,若 x_j 与 x_i 相隔越近,则 P_{ij} 越大,说明它们之间的相似度越高。设定 $P_{ij}=0$ 且数据间的相似度概率和为 1。

引入近邻概率距离,定义如下

$$\hat{d}(x_i, x_j) = \frac{\|x_i - x_j\|^2}{P_{ij}} \quad (9)$$

其中: P_{ij} 为 x_i 选择 x_j 作为近邻的概率。

由式(9)可知,当 $\|x_i - x_j\|^2$ 为一定值时,若 x_i 与 x_j 为同类, P_{ij} 的数值趋于 1,即数据类内距离小;若 x_i 与 x_j 为异类, P_{ij} 的数值趋于 0, $\hat{d}(x_i, x_j)$ 随着 P_{ij} 变小而增大,即数据类间距离增大。

2.2 NPDLE 算法设计

由节 1.3 可知,LE 算法构造近邻图的方式有 ϵ -或 K 近邻两种, ϵ 近邻中 ϵ 的选择通常需要大量实验才能得到最佳效果,而且 ϵ 近邻方式不适用于数据分布不均匀的情况,故根据文献[14],笔者选用 K 近邻方法构建近邻图。NPDLE 算法具体步骤如下。

1) 采用式(9)为距离度量构建近邻图,确定 k 个近邻。

2) 构建权值矩阵。权值矩阵是对近邻图中的边进行赋值,如果能在定义权值时也考虑两点作为近邻的概率问题,使空间中距离近的点间权值更大,且映射后在低维空间仍保持近邻关系,故对权值矩阵重新定义

$$W_{ij}^c = \begin{cases} W_{ij} + \alpha P_{ij} \\ 0 \end{cases} \quad (10)$$

其中: α 为人为设定的参数。

3) 计算投影矩阵。用 W_{ij}^c 代替 W_{ij} 求解式(7),得到的 m 个最小非零特征值对应的特征向量就构成投影矩阵 $A=[a_1, a_2, \dots, a_m]$,通过投影矩阵 A 对数据进行降维处理 $Y=A^T X$ 。

3 基于 IMF 奇异值熵和 NPDLE 的故障诊断方法设计

3.1 IMF 的评价指标

峭度是一种无量纲参数,它对冲击脉冲及脉冲类故障信号特别敏感。当转子无故障时,其振动信号符合正态分布;当发生故障时,由缺陷引起的冲击信号概率密度会增加,故障信号幅值会偏离正态分布导致峭度值增大。峭度值越大,振动信号中包含的故障冲击成分就越多,故障特征信息也就越多。因此,可以利用峭度值的大小作为 IMF 分量的筛选准则,同时计算 IMF 分量与原始信号间的欧式距离,欧式距离值越小则表示与原始信号越相似。为选取含有丰富故障信息的 IMF 分量,本研究将此两项评价指标相结合用于 IMF 分量筛选的依据。

3.2 故障诊断方法流程

在本研究中,基于 IMF 奇异值熵和 NPDLE 的故障诊断流程如图 1 所示。算法具体步骤如下:

- 1) 对采集的不平衡、不对中、碰摩、松动和正常 5 种状态信号进行 EEMD 分解,分别得到若干个 IMF 分量和一个余项;
- 2) 计算各 IMF 分量的峭度、欧式距离两个评价指标,根据其特性分别从转子 5 种状态中筛选含有故障特征信息丰富的 IMF 分量组成初始特征向量矩阵 T ,结合信息熵算法用式(8)计算出奇异值熵矩阵 X ;
- 3) 将特征向量矩阵 X 用 NPDLE 算法进行维数约简得到低维敏感子集 Y ;
- 4) 将低维敏感子集 Y 输入到 KNN 中进行模式识别,辨识出测试样本的故障类型。




图 1 基于 IMF 奇异值熵和 NPDLE 故障诊断流程图
Fig.1 Flow chart of fault diagnosis based on IMF singular value entropy and NPDLE

4 实验结果分析

采用加州大学欧文分校(UCI)数据库中的 Iris

仿真数据集^[16]与转子故障模拟实验数据,分别对文中所提 NPDLE 算法进行验证。

4.1 Iris 仿真数据实验

Iris 数据集包含 4 个属性特征、3 个类别(“*”,“×”,“○”分别代表类别 1,类别 2,类别 3),每个类别包含 50 个样本,共计 150 个样本。为验证 NPDLE 方法的有效性,将仿真数据集经主成分分析方法(principal component analysis,简称 PCA)、LE 和 NPDLE 降维,目标维数为 2,图 2 分别为原始数据与 PCA,LE,NPDLE 降维后的特征分布图。可以看出:原始数据集类别 2 与类别 3 交叉混叠在一起;经 PCA 约简后第 1 类数据可以分离,但第 2 类与第 3 类数据有部分发生混叠,且样本类内距较大,类间距较小,聚类效果较差;经 LE 约简后类别 1 被分离,其他两类仍有混叠,聚类效果有所改善但仍不理想;而经 NPDLE 约简后 3 类数据基本可以分离开,类内距离小,类间距明显,聚类效果较好。最后,将低维特征子集输入 KNN 分类器中进行故障识别,如表 1 所示。




图 2 仿真数据特征分布图
Fig. 2 Features map of simulation data

表 1 不同降维方法识别率($d=2$)

reduction method ($d=2$)			
原始	PCA	LE	NPDLE
0.90	0.91	0.95	0.98

4.2 转子故障模拟实验

所使用的转子故障数据集源于文献^[17]中所示的实验台。实验数据选取在采样频率为 5kHz、驱动电机转速为 2.8kr/min 下采集的振动信号。笔者选择前 12 个通道的数据进行处理,模拟支座松动、动静碰摩、质量不平衡和轴系不对中 4 种典型故障以及正常状态下的实验。每种状态取 50 组样本,其中 30 组用于训练,20 组用于测试。

图 3 为测得 5 种状态下原始振动信号的时域波形图(仅列出不对中状态下的第 1 个通道的原始振动信号)。对图 2 信号进行特征提取分析,对每种状态的每个通道(共 12 通道)的振动信号进行 EEMD 处理,以信号长度为 2 048 个点的不对中故障数据为例进行说明。本实验中 EEMD 的辅助白噪声标准差设为原始标准差的 0.2 倍,且 $M=100$ ^[5]。以不对中的故障信号为例,其分解结果如图 4 所示。由于受到加入白噪声、迭代次数等的影响,EEMD 分解中存在伪分量。为选出能反映故障信息的真实 IMF 分量,提出一种基于峭度和欧式距离的 IMF 分量评价方法。由评价指标性质可知,应从若干 IMF 分量中筛选峭度较大且欧式距离较小的 IMF 分量,构造所需的数据集。




图 3 不对中状态振动信号波形图
Fig. 3 The vibration signal waveform of misaligned state

不对中故障信号 EEMD 分解的各 IMF 分量的两个评价指标情况如图 5 所示。从图 5 可以发现,11 个 IMF 分量中的峭度值、欧式距离均各不相同,第 1 个分量的峭度值较小且欧式距离较大,根据 3.1 节两个评价方法性质将其剔除。

计算筛选后的 IMF 奇异值熵,如图 6 所示。由图可知,转子故障不同信号分解后所得含有故障信息的奇异值熵差异较小,使得转子 5 种状态的奇异值熵区间模糊,类别区间交集明显,难以区分出故障类别。这表明传统的 IMF 奇异值熵这单一判据,不能准确地区分出故障类别。为精确区分出故障类型,笔者在 IMF 奇异值熵的基础上构建特征矩阵 $\mathbf{X}$,采用 NPDLE 算法对故障特征矩阵 $\mathbf{X}$ 进行处理。




图 4 不对中状态故障信号 EEMD 分解图

Fig. 4 EEMD decomposition of misaligned state




图 5 IMF 分量的两个评价指标图

Fig. 5 Two evaluation indexes of IMF component




图 6 EEMD 奇异熵分布图

Fig. 6 The chart of EEMD singular value entropy

4.3 参数的确定

需要设定的参数有:维数约简的目标维数 d , NPDLE 中近邻参数 k_1 、权值矩阵参数 α 以及 KNN 中的近邻参数 k_2 。其中,参数 d 的选取参考文献[18]中所提方式,即目标维数为 4。不同的 k_1 与 α 相组合得到的降维效果在 KNN(固定参数 $k_2 = 8$ [14])中体现出的结果不同,设置 k_1 取值范围为 5~20,步长为 1, α 的取值范围为 0.1~1,步长为 0.1,对所有的 k_1 和 α 进行计算,结果如图 7 所示。




图 7 整体识别率随 k_1 与 α 的变化

Fig. 7 The overall recognition rate change with k_1 and α

由图 7 可以看出:当 $k_1=6$ 时,整体识别率相比于其他情况更好,虽然 k_1 取其他值时也出现识别率较高的情况,但是起伏较大不稳定;当 $k_1=6, \alpha=0.7$ 时,整体识别率达到最大值 98%。为更好地说明参数选择情况,采用固定单一分量 $\alpha=0.7$ 和 $k_1=6$ 的方法,结果如图 8 所示。

4.4 不同方法识别性能的对比

为了验证 NPDLE 算法的降维效果,笔者采用 PCA、等距映射法(isometric mapping,简称 ISO-MAP)、局部保持投影(locality preserving projection,简称 LPP)及 LE 等降维方法与之进行对比。




图 8 k_1 和 α 参数选择曲线图

Fig. 8 k_1 and α parameter selection curve

前 3 个主元的低维嵌入效果如图 9 所示,其中:“*”,“×”,“○”,“☆”和“◇”分别代表转子不对中、质量不平衡、动静碰摩、轴承松动及正常各个状态,各降维方法的故障辨识结果如表 2 所示,表 3 为各方法运行所需时间。

表 2 不同降维方法识别率 ($d=4$)

Tab. 2 The accuracy of different dimensionality reduction method ($d=4$)

降维方法	各状态类别的诊断准确率					平均识别率
	不对中	不平衡	碰摩	松动	正常	
PCA	80.0	95.0	100.0	65.0	75.0	83.0
LPP	75.0	75.0	100.0	90.0	95.0	87.0
ISOMAP	95.0	100.0	60.0	80.0	85.0	84.0
LE	75.0	100.0	100.0	75.0	90.0	88.0
NPDLE	90.0	100.0	100.0	100.0	100.0	98.0

表 3 不同降维方法运行时间

Tab. 3 Different dimensionality reduction method running time

PCA	LPP	ISOMAP	LE	NPDLE	s
0.932	0.797	1.938	0.936	0.923	

由图 8、表 2 和表 3 可知:

1) PCA 和 ISOMAP 聚类效果较差,降维后的




图 9 不同算法的降维效果

Fig. 9 Different dimension reduction method results

各类混叠在一起,识别准确率也比较低,而且算法运行时间也较长,这是因为在挖掘故障数据的低维流行特征时全局保持的算法相较于局部保持的算法效果不明显,导致降维与分类效果不佳;

2) LPP,LE 和 NPDLE 降维后的识别正确率要优于 PCA 和 ISOMAP,这是因为局部保持的流形学习方法能更好地反映低维坐标下的流形特征,降维后故障分类与聚类效果明显提升;

3) NPDLE 降维识别率取得最优,算法运行时间也相对较短,这是因为 NPDLE 相比 LE,它利用一种概率距离的形式来判断数据点之间是否近邻,对于传统 LE 算法中近邻与权重选取不准确的问题有了很好的改善,能够更好地对故障样本间的特征相关性进行描述,实验表明 NPDLE 在维数约简方面显现出更好的性能,更利于后期故障辨识。

为进一步说明 NPDLE 降维算法的有效性,文献[19]将类间离散度和类内离散度的相关比值 J_c 作为评价指标,进行算法有效性的评估。 J_c 越大,说明类内聚集度越好,类间离散度越大,降维效果越好。评价结果如表 4 所示。

表 4 各个算法降维后的类间类内评价指标

Tab. 4 Each dimension reduction algorithm using the evaluation index in between the classes

降维方法	评价指标 J_c
PCA	2.531 0
LPP	3.857 3
ISOMAP	4.754 7
LE	6.021 4
NPDLE	6.241 9

由表 4 可知,PCA 降维后的效果最差,NPDLE 最好,评价标 J_c 达到了 6.241 9,大于其他算法。因此,NPDLE 降维效果相较于其他算法更有优势。

5 结束语

针对转子故障信息提取质量不高导致故障类型难以有效辨识的问题,提出一种 IMF 奇异值熵和 NPDLE 维数约简相结合的转子故障特征提取方法。首先,利用基于峭度、欧式距离的 IMF 分量故障信息含量的评价方法,选出 EEMD 分解后含有丰富故障信息的 IMF 敏感特征集,利用奇异值分解计算其奇异值熵,对模态分量进行量化,并构造特征矩阵;其次,将近邻概率距离引入拉普拉斯特征映射算法中,利用 NPDLE 对奇异值熵数据特征集进行维数约简,融合近邻概率距离的 NPDLE 对比 LE 具

有更好的维数约简能力,可以更有效地提取出低维敏感的特征子集;最后,将低维特征子集输入到分类器中实现故障类别的划分,并利用评估参数 J_c 对降维算法进行有效性评估。实验结果表明,所提方法能够对高维转子故障数据集进行有效的特征提取,为转子故障诊断提供了一种新的解决思路。

参 考 文 献

[1] 马再超,赵荣珍,杨文瑛. 转子故障特征数据分类的 KPCA-BFDA 方法[J]. 振动、测试与诊断, 2013, 33(2):192-198.
MA Zaichao,ZHAO Rongzhen,YANG Wenbiao. KP-CA-BFDA method for rotor fault feature data classification [J]. Journal of Vibration, Measurement & Diagnosis, 2013, 33(2): 192-198. (in Chinese)

[2] 王雪冬,赵荣珍,邓林峰. 基于 KSLPP 与 RWKNN 的旋转机械故障诊断[J]. 振动与冲击, 2016, 35(8): 219-223.
WANG Xuedong, ZHAO Rongzhen, DENG Linfeng. Fault diagnosis of rotating machinery based on KSLPP and RWKNN[J]. Journal of Vibration and Shock, 2016, 35(8): 219-223. (in Chinese)

[3] HUANG N E, SHEN Z, LONG S R, et al. The empirical mode decomposition and the hilbert spectrum for nonlinear and non-stationary time series analysis [J]. Proceedings Mathematical Physical & Engineering Sciences, 1998, 454(1971):903-995.

[4] 何正嘉. 现代信号处理及工程应用[M]. 西安:西安交通大学出版社,2007:230-231.


[5] WU Z H,HUANG N E. Ensemble empirical mode decomposition: a noise-assisted data analysis method[J]. Advances in Adaptive Data Analysis, 2009, 1(1): 1-41.

[6] 王涛,岳贤龙,顾雪平,等. 基于奇异值熵和潮流分布熵的电网关键节点辨识[J]. 电力自动化设备, 2016, 36(4):46-53.
WANG Tao, YUE Xianlong, GU Xueping, et al. Identification of key nodes in power grid based on singular value entropy and power flow distribution entropy[J]. Electric Power Automation Equipment, 2016, 36(4): 46-53. (in Chinese)

[7] FÉGEANT O. Structural mobilities for the edge-excited, semi-infinite cylindrical shell using a perturbation method[J]. Journal of Sound & Vibration, 2001, 248(3):499-519.

[8] 李月仙,韩振南,黄宏臣,等. 基于拉普拉斯特征映射的旋转机械故障识别[J]. 振动与冲击, 2014,

- 33(18):21-25.
- LI Yuexian, HAN Zhennan, HUANG Hongchen, et al. Fault identification of rotating machinery based on Laplacian feature mapping[J]. Journal of Vibration and Shock, 2014, 33(18): 21-25. (in Chinese)
- [9] 王微. 融合全局和局部信息的度量学习方法研究[D]. 合肥:中国科学技术大学, 2014.
- [10] HINTON G, ROWEIS S. Stochastic neighbor embedding[J]. Advances in Neural Information Processing Systems, 2003, 15(3): 833-840.
- [11] 宁少慧, 韩振南, 武学峰, 等. EEMD 和 TFPF 联合降噪法在齿轮故障诊断中的应用[J]. 振动、测试与诊断, 2017, 37(5): 165-171.
- NING Shaohui, HAN Zhennan, WU Xuefeng, et al. Application of EEMD and TFPF combined noise reduction method in gear fault diagnosis[J]. Journal of Vibration, Measurement & Diagnosis, 2017, 37(5): 165-171. (in Chinese)
- [12] 张晓涛, 李伟光. 基于奇异值和奇异向量的振动信号降噪方法[J]. 振动、测试与诊断, 2018, 38(3): 553-558.
- ZHANG Xiaotao, LI Weiguang. Vibration signal denoising method based on singular value and singular vector[J]. Journal of Vibration, Measurement & Diagnosis, 2018, 38(3): 553-558. (in Chinese)
- [13] HOU Z. Adaptive singular value decomposition in wavelet domain for image denoising[J]. Pattern Recognition, 2003, 36(8): 1747-1763.
- [14] 王浩任, 黄亦翔, 赵帅, 等. 基于小波包和拉普拉斯特征值映射的柱塞泵健康评估方法[J]. 振动与冲击, 2017, 37(22): 45-50.
- WANG Haoren, HUANG Yixiang, ZHAO Shuai, et al. Health assessment method of plunger pump based on wavelet packet and Laplacian eigenvalue mapping[J]. Journal of Vibration and Shock, 2017, 37(22): 45-50. (in Chinese)
- [15] 黄宏臣, 韩振南, 张倩倩, 等. 基于拉普拉斯特征映射的滚动轴承故障识别[J]. 振动与冲击, 2015, 35(5): 128-134.
- HUANG Hongchen, HAN Zhennan, ZHANG Qianqian, et al. Fault identification of rolling bearings based on Laplace characteristic map[J]. Journal of Vibration and Shock, 2015, 35(5): 128-134. (in Chinese)
- [16] Blake C L, Merz C J. UCI repository of machine learning databases [EB/OL]. [2018-12-11]. <http://archive.ics.uci.edu/ml/>
- [17] 霍天龙, 赵荣珍, 胡宝权. 基于熵带法与 PSO 优化的 SVM 转子故障诊断[J]. 振动、测试与诊断, 2011, 31(3): 279-284.
- HUO Tianlong, ZHAO Rongzhen, HU Baoquan. Fault diagnosis for rotor systems based on entropy band method and support vector machine optimized by PSO[J]. Journal of Vibration, Measurement & Diagnosis, 2011, 31(3): 279-284. (in Chinese)
- [18] 王泽杰, 胡浩民. 流形学习算法中的参数选择问题研究[J]. 计算机应用与软件, 2010, 27(6): 84-85.
- WANG Zejie, HU Haomin. Research on parameter selection in manifold learning algorithm[J]. Computer Applications and Software, 2010, 27(6): 84-85. (in Chinese)
- [19] 吴剑. 基于特征选择的无监督入侵检测方法[J]. 计算机工程与应用, 2011, 47(26): 79-82.
- WU Jian. Unsupervised intrusion detection method based on feature selection[J]. Computer Engineering and Applications, 2011, 47(26): 79-82. (in Chinese)



第一作者简介:孙泽金,男,1991年2月生,硕士生。主要研究方向为旋转机械故障诊断。

E-mail: 641791315@qq.com