

信息熵融合的 PSO-SVC 涡旋压缩机故障诊断*

刘 涛, 梁成玉

(兰州理工大学机电工程学院 兰州, 730500)

摘要 针对涡旋压缩机振动信号的不稳定性及难以获取大量故障样本的问题,提出了一种信息熵融合与粒子群优化(particle swarm optimization,简称 PSO)的支持向量回归(support vector classification,简称 SVC)涡旋压缩机故障诊断方法。通过奇异谱熵和功率谱熵分析,分别提取振动信号时域与频域特征,采用变分模态分解(variational mode decomposition,简称 VMD)能量熵衡量故障振动信号时-频域特征,利用因子分析融合奇异谱熵、功率谱熵和能量熵值得到单一评价指标特征向量。将评价指标作为 PSO-SVC 模型的输入,通过训练建立 PSO-SVC 涡旋压缩机故障分类模型。实验结果表明,该方法在小样本情况下,仍能有效地对涡旋压缩机 4 种典型故障类型进行分类,准确率达到 94.5%。

关键词 信息熵融合;粒子群优化-支持向量回归;涡旋压缩机;故障诊断

中图分类号 TH455

引 言

涡旋压缩机是一种节能、高效、绿色的回转式流体机械,被广泛应用于空调、制冷、各种气体压缩、发动机增压及液压泵等场合,近年来已扩展到涡旋增压器、涡旋泵和涡旋膨胀机等领域^[1-3]。涡旋压缩机作为核心部件,其性能直接影响系统工作的可靠性。因此,对涡旋压缩机的故障类型进行有效分析与识别至关重要。涡旋压缩机振动信号的复杂性在不同的时间尺度上都有所体现,学者们在这方面进行了研究。邬再新等^[4]建立了一种基于时域的奇异谱熵、频域的功率谱熵、时频小波能量谱熵和小波空间特征谱熵的故障诊断方法,实现了对涡旋压缩机故障的识别,但是对于轴承松动故障和涡旋盘故障区分不佳。刘涛等^[5]运用马氏距离对不同尺度下的涡旋压缩机振动信号进行了定量分析,但这种方法的平均诊断率不高,且特征参数选取存在不确定性。马转霞等^[6]基于奇异值分解降噪提取涡旋压缩机故障特征,建立了涡旋压缩机的排序熵特征模型;然而排序熵是一维时间序列,对于涡旋压缩机复杂的振动信号而言,该方法存在一定的偏差。李亚晨等^[7]提出了奇异值谱与支持向量机(support vector machine,简称 SVM)相结合的涡旋压缩机故障诊断方法,实现了涡旋压缩机的故障分类。该方法未涉及

频域及时频特征分析,故不能准确、全面地识别出故障类型。张明等^[8]通过信息融合构建故障诊断框架,使用径向基神经网络实现了涡旋压缩机的故障分类,但不能解释推理过程且对小样本故障信号识别不佳。

为了解决涡旋压缩机故障振动信号在小样本情况下难以识别的问题,笔者提出了一种信息熵融合与粒子群优化的支持向量回归涡旋压缩机故障诊断方法。基于奇异谱熵和功率谱熵分析涡旋压缩机故障振动信号的时域与频域特征,采用 VMD 能量熵衡量时-频联合域中的故障振动信号特征,利用因子分析计算 3 种信息熵值的权重,将多种熵值融合为单一评价指标。利用 SVC 的分类优势,将评价指标与对应的故障类型作为训练集输入到 PSO-SVC 模型中,使用训练好的模型完成对测试样本的验证,从而实现涡旋压缩机故障类型的辨识。

1 振动信号的信息熵特征

1.1 时域信息熵特征

一般情况下收集的信号为离散时间序列,这种序列存在多种时域分析。对于含有噪声的信号,笔者提出了在时域中较适用的奇异谱熵法。对于给定的 $[x_1, x_2, L, x_M]$ 时间序列,采用延时技术,设定窗

* 国家自然科学基金资助项目(51665035)

收稿日期:2020-02-21;修回日期:2020-06-10

口长度为 M , 构造嵌入空间 $N - M + 1$ 行 M 列的轨迹矩阵, 即

$$R = \begin{bmatrix} x_1 & x_2 & L & x_M \\ x_2 & x_3 & L & x_{M+1} \\ M & M & L & M \\ x_{N-M+1} & x_{N-M+2} & L & x_N \end{bmatrix} \quad (1)$$

对 R 进行奇异值分解, 假设获得的奇异值 $\mu_1 \geq \mu_2 \geq L \geq \mu_M$, 则 $\{\mu_i\}$ 构成了振动信号的奇异值谱。设 k 为非零奇异值的个数, 则 k 值反映了 R 各列中包含的不同模式的数目。定义信号的奇异谱熵为

$$S_1 = - \sum_{i=1}^M q_i \lg q_i \quad (2)$$

其中: $q_i = \mu_i / \sum_{i=1}^M \mu_i$ 为第 i 个奇异值在整个奇异值谱中所占的比重, 即第 i 个模式在整个模式中的比重。

从奇异谱熵的定义可看出, 振动信号越复杂, 则信号的模式越多; 相反, 振动信号越简单, 能量越集中于少数几个模式。

1.2 频域信息熵特征

设振动信号 $x(t)$ 的离散傅里叶变换为 $X(\omega)$, 则信号的功率谱可表示为 $S(\omega) = \frac{1}{2\pi N} |X(\omega)|^2$ 。因信号从时域变换到频域的过程是能量守恒的, 所以功率谱 $S(\omega) = \{S_1, S_2, \dots, S_n\}$ 可以看作是原始振动信号在频域中的一种划分^[9]。定义频域中振动信号的功率谱熵为

$$S_2 = - \sum_{i=1}^N p_i \lg p_i \quad (3)$$

其中: $p_i = S_i / \sum_{i=1}^N S_i$ 为第 i 个谱值在整个功率谱中所占百分比。

功率谱熵是振动信号从频域的角度出发定义的一种信息熵, 可以表示谱分布的相对峰度或平坦度, 功率谱越平坦, 其功率谱熵越大

1.3 时-频域信息熵特征

奇异谱熵和功率谱熵是对信号从时域与频域 2 个角度进行的特征描述, VMD 能量熵可以在时-频联合域中分析信号的复杂性。其中, 最关键的是最佳模态分解和最优解, 采用维纳滤波构造出原始信号 $x(t)$ 的变分问题, 并将振动信号分解为多个本征模函数 (intrinsic mode function, 简称 IMF) 分量, 这些 IMF 分量都有各自的中心频率和带宽。具体的

计算过程如下。

1) 利用 VMD 对振动信号 $x(t)$ 进行分解, 计算 IMF 分量 $u_k(t)$, 构造的约束性变分模型为

$$\min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \quad (4)$$

$$\text{s.t.} \quad \sum_{k=1}^K u_k(t) = x(t)$$

其中: $\{u_k(t)\} = \{u_1, u_2, \dots, u_K\}$ 为分解得到的 K 个 IMF 分量; $\{\omega_k\} = \{\omega_1, \omega_2, \dots, \omega_K\}$ 为各 IMF 分量的中心频率。

2) 根据式 (5) 求出各个 IMF 分量 $u_k(t)$ 的能量 E_k

$$E_k = \sum_{k=1}^K |u_k(t)|^2 \quad (5)$$

3) 求信号的 VMD 能量熵

$$S_3 = - \sum_{k=1}^K p_k \lg p_k \quad (6)$$

其中: $p_k = E_k / E$, 为第 k 个 IMF 模态分量的能量 E_k 占各个 IMF 能量为元素构造总能量 E 的比重。

2 信息熵融合的 PSO-SVC 涡旋压缩机故障诊断方法

2.1 因子分析

在多个因子评价多个指标时, 希望用一个融合后的因子评价一个指标, 由此这里引入了因子分析法。在保留原有信息的前提下, 多个相关指标通过线性变换转化成若干个不相关的公共因子, 进而揭示其内部关系。因子分析不仅可以消除指标之间的相关共线关系, 还可以确定各指标的权重, 已被广泛应用于综合评价中^[10]。

假设 m 个可能相关的评价指标 $X_1, X_2, \dots, X_r$ 包含 m 个相互独立的公因子 $F_1, F_2, \dots, F_m$ ($r \geq m$), 且这些公共因子之间互不相关。每一项评价指标 X_i 中都有一个独特的因子 U_i ($i = 1, 2, \dots, r$) 存在, 各个 U_i 之间是相互独立的, 且 U_i 与 F_j ($j = 1, 2, \dots, m$) 之间也互不相关, 则每个 X_i 可以由 m 个公因子和与其对应的唯一因子 U_i 线性表示

$$\begin{cases} X_1 = a_{11}F_1 + a_{12}F_2 + \dots + a_{1m}F_m + c_1U_1 \\ X_2 = a_{21}F_1 + a_{22}F_2 + \dots + a_{2m}F_m + c_2U_2 \\ \vdots \\ X_r = a_{r1}F_1 + a_{r2}F_2 + \dots + a_{rm}F_m + c_rU_r \end{cases} \quad (7)$$

$$\begin{cases} f_{ij} = a_{ij} / \sqrt{\lambda_j} \\ g_i = \sum_{j=1}^m r_j f_{ij} / \sum_{j=1}^m r_j \sum_{i=1}^n g_i \end{cases} \quad (8)$$

其中: $i=1, 2, \dots, r$; $j=1, 2, \dots, m$; a_{ij} 为因子的负荷系数; λ_j 和 r_j 为第 j 个公因子的特征值和方差贡献率; f_{ij} 为第 j 个因子在第 i 个指标上的决策矩阵系数; g_i 为指标 i 的权重。

2.2 PSO-SVC 算法

SVC 是 SVM 用于分类的一种算法。PSO 是用于优化的一类算法, 模仿鸟类捕食行为得出的一种并行优化启发式算法。通过 SVC 的训练, 选用以高斯函数式 (9) 作为其核函数的训练模式, 建立的 SVC 模型受惩罚系数 c 和核函数参数 g 的影响, 通过 PSO 算法优化 SVC 参数之后, 能够找到最优分类参数 c 和 g , 以此确定分类模型。

PSO 优化 SVC 模型的步骤如下。

1) 确定参加的粒子个数与进行迭代次数、SVC 模型的训练集和测试集, 设置 c 和 g 的搜索区间

$$K(X_k, X_l) = \exp\left(-\frac{\|X_k - X_l\|^2}{\delta^2}\right) \quad (k, l=1, 2, \dots, n) \quad (9)$$

2) 对粒子初始化位置 $X_i = (X_1, X_2, \dots, X_n)$ 和速度 $v_i = (v_1, v_2, \dots, v_n)$, $i=1, 2, \dots, n$, 得到解集的方向方程为

$$v_i^{k+1} = \omega v_i^k + c_1 r_1 (P_i^k - X_i^k) + c_2 r_2 (G_i^k - X_i^k) \quad (10)$$

$$X_i^{k+1} = X_i^k + v_i^{k+1} \quad (11)$$

其中: ω 为惯性权重; k 为迭代次数; c_1, c_2 为非负常量, 称为加速度因子; r_1, r_2 为位于 $[0, 1]$ 之间的随机数; P_i^k 为粒子自身最佳位置; G_i^k 为最佳粒子群位置。

3) 通过计算适应度函数, 找到其适应标准, 改变个体的速度 v , 找到最佳适应方向。

4) 若上述步骤满足, 则终止条件, 并执行第 5 步, 否则将继续循环进行第 3 步。

5) 满足条件时输出 c 和 g 的最佳解, 并将最佳解保存。

6) 在分类模型中, 利用最佳解 c, g 和 SVC 分类模型对测试样本进行分类识别。

2.3 诊断步骤

基于信息熵融合的 PSO-SVC 诊断流程图如图 1 所示, 其具体步骤为:

1) 获取涡旋压缩机故障振动信号, 并提取时域、频域及时-频域的特征信息;

2) 根据式 (2), (3), (6) 计算信息熵;

3) 通过因子分析将步骤 2 中所得信息熵进行融合, 计算公式如 (7), (8) 所示, 得到各个信息熵的权重, 按照权重融合为单一评价指标;

4) 利用 PSO 算法对 SVC 进行参数寻优, 设定 c 和 g 的搜索区间;

5) 求解式 (10), (11), 确定目标函数;

6) 选择 SVC 模型的训练集和测试集;

7) 输入与评价指标对应的故障类型作为训练集到 PSO-SVC 模型中, 训练故障类型模型函数;

8) 用训练好的 SVC 故障分类模型对测试样本进行故障识别。




图1 信息熵融合的PSO-SVC诊断流程图

Fig.1 Information entropy fusion of PSO-SVC diagnosis process

3 实验结果与分析

3.1 实验装置

实验验证的振动数据来自兰州理工大学涡旋机械研究所的涡旋压缩机, 样机如图 2 所示, 样机参数如表 1 所示。硬件系统结构框图如图 3 所示, 其中, 压电式传感器为 YD-5-2 和 YD-8, 数据采集型号为 PCI-6221, 变频器型号为 FRN55P11S-4CX。软件系统基于 LabVIEW 软件开发, 人机交互的设计使用 TAB 模块完成程序的集成, 形成的涡旋压缩机振动测试平台主界面如图 4 所示。



图 2 涡旋压缩机样机

Fig.2 Scroll compressor prototype

表 1 样机参数

Tab.1 Parameters of the prototype

主要参数	数值
转速/(r·min ⁻¹)	3 120.0
转频/Hz	52.1
采样频率/Hz	2 000.0
采样点数	2 048




图 3 硬件系统结构框图

Fig.3 Hardware system structure diagram




图 4 涡旋压缩机振动测试平台主界面

Fig.4 Scroll compressor vibration test platform main interface

涡旋压缩机测试点如图 5 所示。比较涡旋压缩机不同测试点的振动量,发现 1#,5#,7#和 8#的振动幅值最大,测试点对应的位置分别是涡旋压缩机的顶部、动静涡旋盘的啮合处、安装电机的位置以及压缩机的底部。因此,笔者选择这 4 个位置采集和分析 4 种典型故障信号,图 6~9 分别为涡旋盘故障、转子不平衡故障、轴承松动故障及机械组装松动故障。

3.2 结果分析

提取故障样本熵值,部分训练集故障样本信息熵值如表 2 所示。笔者重点分析涡旋盘故障,通过




图 5 涡旋压缩机测试点

Fig.5 Test point of scroll compressor




图 6 涡旋盘故障

Fig.6 The fault of scroll




图 7 转子不平衡故障

Fig.7 The fault of rotor unbalance

因子分析融合涡旋盘故障的 3 种信息熵值,融合为单一的评价指标。由表 2 可见,转子不平衡故障的 3 种熵值是最小的,其振动以基频为主,能量比较集中,不确定性较低。涡旋盘故障熵值其振动能量较转子不平衡集中,一般由自身的固有频率引起。对于机械组装松动的熵值,由于其长期运行导致内部部件松动,出现摩擦。轴承松动故障的熵值最大,因转子失稳导致了出现了多个振动分量,因此能量分布的复杂性较大。




图 8 轴承松动故障

Fig.8 The fault of bearing loosening




图 9 机械组装松动故障

Fig.9 The fault of mechanical assembly loosening

表 2 训练集故障样本信息熵值

Tab.2 Entropy value of fault samples in training collection

类型	奇异谱熵 S_1	功率谱熵 S_2	VMD 能 谱熵 S_3
涡旋盘故障 $X_0(1)$ 样本(1~100)	1.921	2.264	2.290
	1.925	2.276	2.319
	⋮	⋮	⋮
	1.934	2.284	2.399
	1.928	2.281	2.357
转子不平衡 $X_0(2)$ 样本(1~100)	1.454	1.651	1.659
	1.449	1.647	1.679
	⋮	⋮	⋮
	1.451	1.638	1.698
	1.440	1.642	1.691
机械组装松动 $X_0(3)$ 样本(1~100)	2.146	2.652	2.440
	2.148	2.660	2.444
	⋮	⋮	⋮
	2.151	2.655	2.396
	2.157	2.683	2.452
轴承松动 $X_0(4)$ 样本(1~100)	2.410	2.823	2.571
	2.411	2.826	2.579
	⋮	⋮	⋮
	2.408	2.819	2.584
	2.402	2.830	2.582

对样本数据进行 Kaiser Meyer Olkin (简称 KMO) 相关系数检验和 Bartlett 球形度验证, 结果如表 3 所示。KMO 测试值为 0.731 (>0.6), 表明涡旋盘故障的评价指标之间的简单相关系数的平方和比所述部分相关系数的平方之和大, 所以因子分析可被执行。同时, 在 Bartlett 球形度检验中, 对应的 $P < 0.001$, 表明各个指标之间存在较强的关联, 非常适合进行因子分析。数据满足因子分析的要求之后, 可确定公因子的方差提取值如表 4 所示。可以看出, 公因子方差提取满足要求, 且 3 个指标的信息提取率都在 85% 以上, 说明模型较好地保留了原指标体系的信息。公因子的总方差如表 5 所示, 以旋转后的相对方差贡献率为权重, 则 3 个指标的权重依次为 0.424, 0.392 和 0.184。计算公因子得分后, 依照权重计算奇异谱熵、功率谱熵、VMD 能量熵构建的涡旋盘故障单一评价指标 $F = 0.424X_1 + 0.392X_2 + 0.184X_3$, 其中: X_1, X_2, X_3 分别为奇异谱熵、功率谱熵和 VMD 能量熵。

表 3 KMO 和 Bartlett 检验

Tab.3 KMO and Bartlett tests

项目	参数	数值
KMO 相关系数检验	相关系数	0.731
	卡方值	217.33
Bartlett 球形度检验	自由度	62
	显著性	0

表 4 公因子方差提取

Tab.4 Common factor variance extraction

涡旋盘故障因子	初始值	提取率/%
奇异谱熵 S_1	1.000	0.961
功率谱熵 S_2	1.000	0.947
VMD 能量熵 S_3	1.000	0.939

涡旋盘熵值曲线如图 10 所示。可以看出, 在涡旋盘故障各个测试样本中, 部分功率谱熵和 VMD 能量熵出现了交叉重叠, 使用单一域的熵值进行故障分类达不到预期效果。可见, 利用熵值融合可以更好地区分出各种故障。

实验得到 600 组数据, 其中 400 组作为训练样本, 每种状态 100 组, 其余 200 组作为测试样本。将构建的涡旋盘故障单一评价指标输入 PSO-SVC 中识别涡旋盘故障。涡旋盘故障分类结果如图 11 所示, 类别标签 2 代表涡旋盘故障。可以看出, 第 3

表 5 公因子总方差
Tab.5 Total variance of common factors

涡旋盘故障指标	初始特征值 λ_j 方差百分 比/%	提取载荷平方和百分 比/%	旋转载荷平方和百分 比/%	方差贡献率 r_j	权重 g_i
奇异谱熵 S_1	41.57	41.89	41.39	90.56	0.424
功率谱熵 S_2	39.38	39.62	38.52	87.14	0.392
VMD 能量熵 S_3	19.72	19.50	20.16	89.78	0.184

个、第 23 个和第 27 个样本未识别出故障类型。




图 10 涡旋盘熵值曲线
Fig.10 Scroll entropy curve




图 11 涡旋盘故障分类结果
Fig.11 The fault classification results of scroll

将此方法用于其他 3 种故障的识别中,在 SVC 的训练和测试中,以径向基函数作为核函数,利用 PSO 进行参数优化,得到最佳参数。PSO 参数寻优如图 12 所示。

图 13 为 PSO-SVC 故障分类结果。用数字标签表示涡旋压缩机故障类型,测试样本存放次序为: 1~50 为机械组装松动故障(标签 1); 51~100 为涡旋盘故障(标签 2); 101~150 为转子不平衡故障(标签 3); 151~200 为轴承松动故障(标签 4)。由图 13 可知,在 200 个测试样本中采用 PSO-SVC 分类方法有 11 个错误分类,分别为第 13, 26, 36, 58, 77, 84,




图 12 PSO 参数寻优
Fig.12 PSO parameter optimization

109, 122, 132, 171, 188 个测试样本,其余测试样本均可识别。综合 4 种故障分类,PSO-SVC 方法在涡旋压缩机故障识别中的平均准确率可达 94.5%,取得较为满意的诊断结果。笔者利用因子分析将 3 种指标融合为一个评价指标,从信息融合的角度看,将时域、频域、时-频域三者合为一体,实现了一个评价指标包含 3 个域信息的可能性。

表 6 为样本测试诊断结果。从分类准确度上看,采用粒子群优化算法构建 PSO-SVC 故障分类模型,对机械组装松动、转子不平衡故障、涡旋盘故障的分类准确率达到 94%。对轴承松动故障的分类准确率达到 96%,综合 4 种故障分类结果,平均准确率可达 94.5%。




图 13 PSO-SVC 故障分类结果
Fig.13 Fault classification results of PSO-SVC

表6 样本测试诊断结果

Tab.6 Common factor variance extraction

故障类型	样本数目	识别样本	诊断准确率/%
涡旋盘故障	50	47	94
机械组装松动故障	50	47	94
轴承松动故障	50	47	94
转子不平衡故障	50	48	96

4 结 论

1) 从分类结果可以看出,信息熵融合的评价指标有效地表征了涡旋压缩机故障信息,可信度较高。利用因子分析融合三个域的熵值得到评价指标,较单一指标对故障信号的表征更加全面与准确。经实验验证后,此方法可以适用其他旋转机械的故障诊断中。

2) 实验结果表明,采用笔者所建立的PSO-SVC模型对涡旋盘、机械组装松动、轴承松动及转子不平衡4种典型涡旋压缩机故障类型进行分类,平均准确率达到94.5%,最大程度上提高了涡旋压缩机故障诊断效率,为涡旋压缩机的故障类型识别提供了一种有效方法。

参 考 文 献

- [1] MOJIRI A, MIKEL M, BARBER T. Geometry of wrap profiles in co-rotating scroll compressors [J]. International Journal of Refrigeration, 2019, 106: 327-337.
- [2] MATEU-ROYO C, NAVARRO-ESBRÍ J, MOTA-BABILONI A, et al. Experimental exergy and energy analysis of a novel high-temperature heat pump with scroll compressor for waste heat recovery [J]. Applied Energy, 2019, 253: 113504.
- [3] TELLO-OQUENDO F M, NAVARRO-PERIS E, BARCEL-RUESCAS F, et al. Semi-empirical model of scroll compressors and its extension to describe vapor-injection compressors model description and experimental validation [J]. International Journal of Refrigeration, 2019, 106: 308-326.
- [4] 郭再新, 刘涛, 黄成东. 基于信息熵的涡旋压缩机振动信号分析[J]. 振动、测试与诊断, 2014, 34(1): 168-172.
WU Zexin, LIU Tao, HUANG Chengdong. Analysis of scroll compressor vibration signal based on information entropy [J]. Journal of Vibration, Measurement & Diagnosis, 2014, 34(1): 168-172. (in Chinese)

- [5] 刘涛, 马转霞, 杜楠. 多尺度排列熵在涡旋压缩机故障诊断中的应用[J]. 兰州理工大学学报, 2018, 44(1): 42-46.
LIU Tao, MA Zhuangxia, DU Nan. Application of multi-scale arrangement entropy in fault diagnosis of scroll compressor [J]. Journal of Lanzhou University of Technology, 2018, 44(1): 42-46. (in Chinese)
- [6] 马转霞, 费维科, 周新涛. 基于奇异值分解降噪与排序熵的涡旋压缩机故障特征提取方法[J]. 机械制造, 2018, 56(6): 94-96.
MA Zhuangxia, FEI Weike, ZHOU Xintao. Fault feature extraction method of scroll compressor based on singular value decomposition and sorting entropy [J]. Machinery Manufacturing, 2018, 56(6): 94-96. (in Chinese)
- [7] 李亚晨, 王珍, 陈建国, 等. 基于奇异值谱与SVM的涡旋压缩机故障诊断方法研究[J]. 压缩机技术, 2017(3): 6-9.
LI Yachen, WANG Zhen, CHEN Jianguo, et al. Study on fault diagnosis method of scroll compressor based on singular value spectrum and SVM [J]. Compressor Technology, 2017(3): 6-9. (in Chinese)
- [8] 张明, 江志农. 基于多源信息融合的往复式压缩机故障诊断方法[J]. 机械工程学报, 2017, 53(23): 46-52.
ZHANG Ming, JIANG Zhinong. Fault diagnosis method of reciprocating compressor based on multi-source information fusion [J]. Journal of Mechanical Engineering, 2017, 53(23): 46-52. (in Chinese)
- [9] 白斌, 白广忱, 李超. 过程功率谱熵在转子振动定量诊断中的应用[J]. 航空发动机, 2015, 41(1): 27-31.
BAI Bin, BAI Guangchen, LI Chao. Application of process power spectrum entropy in quantitative diagnosis of rotor vibration [J]. Aeroengine, 2015, 41(1): 27-31. (in Chinese)
- [10] DENG W, YAO R, ZHAO H, et al. A novel intelligent diagnosis method using optimal LS-SVM with improved PSO algorithm [J]. Soft Computing, 2019, 23(7): 2445-2462.



第一作者简介:刘涛,女,1971年7月生,教授、博士生导师。主要研究方向为机械设计制造及其自动化。曾发表《基于信息熵的涡旋压缩机振动信号分析》(《振动、测试与诊断》2014年第34卷第1期)等论文。

E-mail: cathyliu1999@126.com