

基于平滑先验分析和排列熵的滚动轴承故障诊断^{*}

戴洪德¹, 陈强强^{2,3}, 戴邵武², 朱敏²

(1. 海军航空大学 航空基础学院, 山东 烟台 264000; 2. 海军航空大学 岸防兵学院, 山东 烟台 264000;
3. 海军92728部队, 上海 200040)

摘要: 由于机械系统的复杂性, 滚动轴承振动信号的特征信息表现在不同尺度上, 因此需要对振动信号进行多尺度分析。基于此, 提出一种基于平滑先验分析 (Smoothness priors approach, SPA) 和排列熵 (Permutation entropy, PE) 的滚动轴承故障诊断方法。该方法首先采用平滑先验分析方法代替传统的时间序列分解方法对滚动轴承信号进行分解, 得到轴承信号的趋势项和去趋势项; 其次, 分别计算趋势项和去趋势项的排列熵值; 最后, 将排列熵值作为特征向量, 输入基于粒子群优化支持向量机建立的分类器。将该方法应用于滚动轴承实验数据并进行对比分析, 结果表明, 在训练样本数为每类50%的条件下, 该方法的故障诊断正确率比PE和经验模态分解-PE分别高出12.5%和3.125%。

关键词: 航空发动机; 轴承; 振动; 故障诊断; 支持向量机

中图分类号: TN911.7

文献标识码: A

文章编号: 1001-4055 (2020) 08-1841-09

DOI: 10.13675/j.cnki.tjjs.190135

Rolling Bearing Fault Diagnosis Based on Smoothness Priors Approach and Permutation Entropy

DAI Hong-de¹, CHEN Qiang-qiang^{2,3}, DAI Shao-wu², ZHU Min²

(1. College of Basic Sciences for Aviation, Naval Aviation University, Yantai 264000, China;
2. College of Coastal Defense, Naval Aviation University, Yantai 264000, China;
3. Naval 92728, Shanghai 200040, China)

Abstract: Due to the complexity of mechanical systems, the feature information of the rolling bearing vibration signals behave on different scales, making it necessary to analyze the vibration signal in a multi-scale way. Therefore, an approach for the fault diagnosis of rolling bearings using the permutation entropy (PE) and SPA (Smoothness Priors Approach) is proposed. Firstly, the SPA is used to decompose the rolling bearings vibration signal instead of the traditional time series decomposition method, trend component and de-trend component spanning different scales are obtained. Secondly, the permutation entropy of the trend component and de-trend component, which contain the main fault information is calculated. The permutation entropies are accordingly seen as the characteristic vector, then input to the Particle Swarm Optimization and support vector machine based classifier. Finally, the proposed method is applied to the experimental data. The analysis results show that, comparing to PE and Empirical Mode Decompose-PE, the diagnosis accuracies of the current approach increase by 12.5% and 3.125%, respectively, as the training sample size is 50% per class.

Key words: Aero-engine; Bearing; Vibration; Fault diagnosis; Support vector machine

^{*} 收稿日期: 2019-03-02; 修订日期: 2019-06-27。

基金项目: 山东省自然科学基金面上项目 (ZR2017MF036); 国防科技项目基金 (F062102009)。

通讯作者: 戴洪德, 博士, 副教授, 研究领域为惯性导航、卡尔曼滤波和故障诊断。E-mail: 13181612901@163.com

引用格式: 戴洪德, 陈强强, 戴邵武, 等. 基于平滑先验分析和排列熵的滚动轴承故障诊断[J]. 推进技术, 2020, 41(8): 1841-1849. (DAI Hong-de, CHEN Qiang-qiang, DAI Shao-wu, et al. Rolling Bearing Fault Diagnosis Based on Smoothness Priors Approach and Permutation Entropy [J]. *Journal of Propulsion Technology*, 2020, 41 (8): 1841-1849.)

1 引 言

航空发动机是武器装备的重要组成部分之一,其工作状态直接影响着飞行质量,是保证飞行安全的重要部件之一^[1]。滚动轴承作为发动机等机械设备的基本部件,其工作状态直接影响并决定着航空发动机的性能安全。当轴承存在局部损伤时,会使发动机设备振动异常,更有可能导致设备的损毁^[2]。因此,实现准确的滚动轴承故障诊断具有十分重要的意义。

受发动机工作环境影响,滚动轴承的振动信号多为非线性、非平稳信号。因此如何从非线性、非平稳信号中提取出故障特征信息,是实现滚动轴承故障诊断的首要目标。随着非线性理论在故障诊断领域的发展,许多非线性分析方法得到了广泛应用。文献[3]通过关联维数对航空发动机状态进行了分析,实现了发动机故障状态监控;文献[4]为解决故障判断问题,引入了广义分形维数,代替了单一尺度下的分形维数。文献[5]结合混沌理论与李雅普诺夫指数理论,对发电机组的故障诊断问题进行了研究。这些非线性理论中,关联维数、广义分形维数均存在着依赖数据长度和精度不足等问题,而李雅普诺夫指数在实际使用过程中易受到噪声干扰,限制了其实际应用。

为了直观有效地对时间序列信息进行度量,Yan等^[6]引入了近似熵的概念对机器健康状态进行分析。艾延廷等^[7]通过融合信息熵距对发动机转子裂纹-碰摩耦合故障进行诊断。费成巍等^[8]将过程功率熵谱与支持向量机进行结合,实现发动机转子振动故障诊断。Christoph等^[9]提出了排列熵的概念,用于检测时间序列随机性和动力学突变。PE可有效衡量时间序列的复杂程度,并在医学、机械等多个领域得到广泛应用^[10]。相比近似熵的一致性较差等问题,排列熵算法能够有效检测并扩大信号的变化,反映出信号的内部特征。然而,由于机械设备的复杂性和振动信号的多尺度性,单一尺度下的排列熵算法不足以准确提取出振动信号的信息^[11]。因此,有必要通过多尺度分解方法,在时间序列上对滚动轴承信号进行多尺度分解,从而实现滚动轴承振动信号的多尺度分析。

在时间序列多尺度分解问题中,小波分析最早得到了广泛程度的应用,而小波分析的不足之处在于小波基的选取,不同的小波基对效果有着很大的影响^[12]。Huang等^[13]提出了经验模态分解方法(Em-

pirical mode decompose, EMD),采用三次样条曲线对信号进行自适应分解,能够对信号进行时频聚焦,在滚动轴承故障分析中也有着广泛的应用^[14]。在EMD的基础上^[15],扩展提出了完备经验模态分解(Ensemble empirical mode decompose, EEMD)。文献[16]采用了变分模态分解的方法实现了滚动轴承的故障诊断。这些时间序列分解方法为多尺度下的故障诊断提供了方法,具有一定的实用价值。其不足之处在于这些多尺度分解方法在分解过程中产生了较多的分量,在进行故障诊断问题分析时,一般认为前几个分量中包含了主要故障信息,并选择前几个分量的特征值构成特征向量进行故障诊断分析^[17]。分量的选择一定程度上影响了故障特征提取的自适应性,同时过多分量的特征集在一定程度上造成了信息的冗余。此外,选取的分量信息的特征值在时域特征中过于类似,不具有明显的区分度。

为了解决上述问题,本文提出了基于SPA-PE-PSOSVM的滚动轴承故障诊断方法。首先,采用平滑先验分析(Smoothness priors approach, SPA)方法将振动信号分解为趋势项和去趋势项,这在一定程度上大大降低了分解所得分量的个数,且趋势项与去趋势项之间差异明显,有益于特征向量的构建;然后,对所得的趋势项和去趋势项提取其排列熵;最后,将熵值作为特征向量输入粒子群优化(Particle swarm optimization, PSO)的支持向量机(Support vector machine, SVM),从而实现轴承故障类别的诊断。

与传统的特征提取方法相比,本文提出的方法在趋势项与去趋势项这两个差别较大的分量中提取振动信号的随机性和动力学突变特征,因此相较于传统方法而言,本研究方法更能反映信号故障的本质特征。SPA方法在医学等领域有着一定应用,但在故障诊断领域未见有文献报道。将所提出的方法应用于轴承试验数据,结果表明,该方法能够有效区分滚动轴承的故障类型,是一种有效的故障诊断方法。

2 分解-特征提取及故障诊断方法

为实现滚动轴承不同振动信号的特征提取,本文采用“分解-特征提取”的思想,首先采用时间序列分解方法将信号分解为不同时间尺度。然后对分解所得分量进行PE值求解,以深度挖掘滚动轴承故障信息。

2.1 时间序列分解

在时间序列分解方面,采用较多的是EMD方法及其扩展形式。EMD算法将复杂信号分解为多个固

有模态函数(Intrinsic mode function, IMF)和一个余项, EMD分解的表达式为^[18]

$$S = \sum_{i=1}^n \text{IMF}_i(t) + R(t) \quad (1)$$

式中 S 为源信号; $\text{IMF}_i(t)$ 为第 i 个 IMF 分量; $R(t)$ 为分解得到的余项。待分解信号可表示为分解得到的子序列之和。

EMD 分解的不足之处在于过多的 IMF 分量造成了信息的冗余, 在特征向量提取过程中, 对多个 IMF 分量的特征量求解增加了计算量。在文献[17-19]中, 选择提取前 6 个分量的特征值构建特征向量集。同时, EMD 分解得到的低阶 IMF 分量对应高频特征信息, 前 6 个 IMF 分量之间特征信息近似, 区分度过低。所以, 本文提出采用 SPA 方法对轴承故障信号进行分解。

SPA 最早应用于心电信号处理, 其计算过程简单, 计算量极小, 仅选择单一参数即可快速分量原始数据趋势项和去趋势项(也称为周期项)。目前文献主要应用于电力系统非线性去趋^[20]和滑坡位移分解预测^[21]。

设初始信号为 Z , 其趋势项表示为 Z_t 。对 Z_t 构建线性观测模型为

$$Z_t = H\theta + v \quad (2)$$

式中 H 为观测矩阵, θ 为回归参数, v 表示观测误差。

采用正则化最小二乘法, 通过求解 θ 的最优解 $\hat{\theta}$, 然后根据 $\hat{Z}_t = H\hat{\theta}$ 确定原始数据趋势项, 有

$$\hat{\theta}_\lambda = \arg \min_{\theta} \left\{ \|H\theta - Z\|^2 + \lambda^2 \|D_d(H\theta)\|^2 \right\} \quad (3)$$

式中 λ 为正则化参数; D_d 为第 d 阶微分算子的离散形式表达。

设 Z 原时间序列有 N 个局部极值点, 即

$$Z_t = [Z_1, Z_2, \dots, Z_N] \quad (4)$$

推导得式(4)中任意阶趋势为

$$D_d = \begin{bmatrix} d(Z_{t_d})_1 / dZ_1 & \cdots & d(Z_{t_d})_1 / dZ_N \\ \cdots & \cdots & \cdots \\ d(Z_{t_d})_{N-d} / dZ_1 & \cdots & d(Z_{t_d})_{N-d} / dZ_N \end{bmatrix} \quad (5)$$

使微分项 $\|D_d(H\theta)\| \rightarrow 0$, 求解式(5)可得

$$\hat{\theta}_\lambda = (H^T H + \lambda^2 H^T D_d^T D_d H)^{-1} H^T Z \quad (6)$$

$$\hat{Z}_t = H\hat{\theta}_\lambda \quad (7)$$

为了简化观测矩阵 H 的选择, 选择 H 为单位阵。选择式(5)中的阶次为 2 阶, 形式为

$$D_2 = \begin{bmatrix} 1 & -2 & 1 & 0 & \cdots & 0 \\ 0 & 1 & -2 & 1 & \cdots & \cdots \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & \cdots & 0 & 1 & -2 & 1 \end{bmatrix} \quad (8)$$

消除趋势项后, Z 的去趋势项 Z_{det} 可表示为

$$\hat{Z}_{\text{det}} = Z - H\hat{\theta}_\lambda = (I - (I + \lambda^2 D_2^T D_2)^{-1}) Z \quad (9)$$

式中

$$L = I - (I + \lambda^2 D_2^T D_2)^{-1}$$

则式(9)表示为

$$\hat{Z}_{\text{det}} = LZ \quad (10)$$

L 可视为高通滤波器, 通过选择正则化参数 λ , 可实现对 Z 的趋势项及去趋势项的分离。

通过对 SPA 分解的原理分析可知, SPA 分解所得分量个数与时间序列长度无关, 即所得分量只有趋势项和去趋势项, 这在一定程度上克服了 EMD 分解所得分量过多的不足, 简化了故障诊断中特征向量求取的过程。为了说明 SPA 分解的趋势项提取能力, 采用如下仿真信号进行分析

$$\begin{aligned} x_1 &= [1 + 0.5 \sin(5\pi t)] \sin(120\pi t + 20\pi t^2) \\ x_2 &= \sin(40\pi t) \end{aligned} \quad (11)$$

纯信号 x_3 由公式(11)中的 $x_1 + x_2$ 合成, 在纯信号的基础上, 增加均值为 0, 方差为 1 的高斯白噪声信号并构成含噪信号 x_4 。采样频率为 1024 Hz, 仿真时间 $t \in [0, 1]$ 。

对含噪信号进行 SPA 分解, 原始纯信号、含噪信号及 SPA 分解后的趋势项和去趋势项如图 1 所示。

如图 1 所示, SPA 分解所得趋势项可较好地反映出原始纯信号的特征。采用互相关系数 $\rho_{x_3 t}$ 表示对含噪信号进行 SPA 分解所得的趋势项 t 与纯信号 x_3 之间的相关性; $\rho_{x_3 t}$ 的取值越接近 1, 表示两信号之间的相关性越强。

$$\rho_{x_3 t} = \frac{C_{x_3 t}}{\sigma_{x_3} \sigma_t} \quad (12)$$

计算得到趋势项与纯信号之间的互相关系数为 0.9066, 表明 SPA 分解对含噪信号 x_4 的趋势项提取结果能够很好地表示原始纯信号信息。

鉴于 SPA 分解的分量个数较少及趋势项提取能力较强的特性, 可考虑将其应用于故障诊断中的多尺度分解过程; 通过 SPA 分解所得到的趋势项及去趋势项, 求取其特征量并组成特征向量, 可以概括原始信号在不同分量上的特征信息。




Fig. 1 Simulated signal and SPA results

2.2 排列熵特征提取

在2.1节中,通过对滚动轴承振动信号进行SPA分解,得到特征程度区分明显的趋势项和去趋势项。通过对这两项分量进行特征提取,从而为后续故障诊断提供特征向量。

排列熵算法原理为:针对长度为 N 的时间序列 $\{x(i), i = 1, 2, \dots, N\}$,对 $x(i)$ 进行相空间重构^[22],有

$$\begin{cases} X_1 = \{x(1), x(1+\tau), \dots, x[1+(m-1)\tau]\} \\ X_j = \{x(j), x(j+\tau), \dots, x[j+(m-1)\tau]\} \\ \vdots \\ X_k = \{x(k), x(k+\tau), \dots, x[k+(m-1)\tau]\} \end{cases} \quad (13)$$

式中 m 为嵌入维数, τ 为延迟时间, $k = N - (m-1)\tau$ 为重构向量的个数。

将 X_j 中的元素按升序排列得

$$x[i + (j_1 - 1)\tau] \leq \dots \leq x[i + (j_m - 1)\tau] \quad (14)$$

式中 $j_1, j_2, \dots, j_m$ 为各元素在排序之前位于相空间所在列的索引。

若 X_j 中有两元素相等,则按原始顺序排列。通过对相空间重构后的时间序列分析,对于任意一个

X_j ,均能得到相应的符号序列 $S_l = \{j_1, j_2, \dots, j_m\}$,其中, $l = 1, 2, \dots, k$,且 $k \leq m!$ 。可定义排列熵为^[23]

$$H_p(m) = -\sum_{j=1}^k P_j \ln(P_j) \quad (15)$$

式中 P_j 为符号序列的概率,且 $\sum_{j=1}^k P_j = 1$ 。

若 $P_j = \frac{1}{m!}$,则 $H_p(m) = \ln(m!)$,取值最大。将

$H_p(m)$ 标准化可得

$$H_p = \frac{H_p(m)}{\ln(m!)} \quad (16)$$

此时, H_p 的取值为 $[0, 1]$,可反映出时间序列的复杂程度。 H_p 越大,则序列复杂程度越高。

排列熵算法能够有效衡量时间序列的复杂程度,并检测时间序列随机性和动力学突变,同时能够放大时间序列的微弱变化,适合作为故障诊断的特征。根据排列熵算法的提出者Bandt等建议,在计算排列熵时,嵌入维数 m 不宜过小或过大;如果嵌入维数 m 过小,此时重构的向量中包含的状态太少,不能有效反应时间序列的动力学突变,算法失去其意义;如果嵌入维数 m 过大,则相空间的重构过程会均匀化时间序列,因此一般取3~7;而时间延迟 τ 对计算的影响较小,一般取 $\tau = 1$ ^[19]。

2.3 基于PSOSVM的故障诊断方法

SVM以统计学习为理论基础,通过非线性映射,将原始空间样本数据映射到高维特征空间,从而实现其理论分析^[24]。利用SVM对所提取出的特征信息进行故障诊断时,涉及到核参数及惩罚因子的选择问题。针对这一问题,采用PSO优化方法来实现。

PSO优化算法是智能领域算法中的一种基于群体智能的优化算法,可通过粒子在解空间追随最优粒子进行搜索^[25]。利用PSO方法优化SVM参数框图如图2所示。




Fig. 2 PSO-SVM algorithm

综上所述,本文所提出的SPA-PE-PSOSVM轴承故障诊断方法如下:

首先,采用SPA方法代替传统的时间序列分解方法,自适应地将滚动轴承振动信号分解为趋势项和去趋势项。这两项时间序列均包含着不同频段和不同尺度的故障信息。

其次,应用排列熵原理,分别对趋势项和去趋势项计算其排列熵值,作为滚动轴承故障诊断的特征向量 F ,即

$$F = [PE_{trend}, PE_{detrend}] \quad (17)$$

最后,采用PSO算法优化SVM分类器,并将不同故障类型的特征向量输入至分类器,完成对滚动轴承的故障诊断。

基于SPA-PE-PSOSVM的滚动轴承故障诊断方法的流程图如图3所示。




Fig. 3 Flow chart of rolling bearing fault diagnosis based on SPA-PE-PSOSVM

3 试验分析

为了验证本文所提出的SPA-PE-PSOSVM算法的有效性和准确性,选择6205-2RS JEM SKF深沟球轴承数据作为验证数据。数据来源为Case Western Reserve University电气工程实验室滚动轴承数据集,电机负载为735.5W,轴承转速为1772r/min;故障通过电火花技术布置,直径为0.3556mm,深度为0.2794mm,4种状态的振动信号采样频率为12kHz;数据样本长度为2048;除正常状态(Normal,记为NORM)外,分别记三种故障状态为滚动体故障(Rolling element fault,记为REF)、内圈故障(Inner race fault,记为IRF)和外圈故障(Outer race fault,记为ORF)。

取正常状态、滚动体故障、内圈故障及外圈故障4种状态的样本各80组,共计320组数据。在故障诊断过程中,选择4种状态下各80组数据中的40组作为训练集(50%),余下40组作为测试集(50%),以验证算法的有效性。4种状态下轴承的振动加速度 a 信号如图4所示。

为了验证SPA方法与传统时间序列分解方法之




Fig. 4 Signals from the normal and fault bearing

间的优势,选取其中正常状态NORM为例,采用EMD方法进行分解,选取前6个IMF分量作为展示,结果如图5所示。

经过EMD分解正常状态振动信号,共得到10个IMF分量与1个趋势项,在后续特征提取过程中造成了一定程度的信息冗余,且对多个IMF分量进行排列熵值计算,也增加了计算量。采用SPA算法对同样的正常状态信号进行分解,所得结果如图6所示。

如图6所示SPA分解所得2个分量,其中趋势项保留了原始时间序列的趋势特征,且趋势项与去趋势项之间的差别明显,采用PE进行趋势项与去趋势项的特征向量提取,能够完整概括时间序列的特征。为验证SPA算法是否可行,对所采集4种状态下320个样本的趋势项及去趋势项进行PE求解;其中,PE参数设置参照文献[19]。320个样本的趋势项、去趋势项对应的PE值如图7所示。

如图7所示,参照图5分解结果,SPA分解所得趋势项较为平缓,而去趋势项随机性较大,这在图7中也得到了反映。图7(a)中对应的是趋势项的PE,其幅值较图7(b)而言有着明显的降低。在分类方面对




Fig. 5 EMD decomposition results




Fig. 6 SPA decomposition results

图7进行分析:对趋势项而言,正常状态(NORM)和内圈故障(IRF)的排列熵波动区间有一定的重叠和交叉,直接使用趋势项的排列熵作为滚动轴承的故





Fig. 7 PE of samples


障特征可能会引起误判;对去趋势项而言,内圈故障(IRF)和外圈故障(ORF)的排列熵波动区间有一定的重叠和交叉,直接使用去趋势项的排列熵作为滚动轴承的故障特征可能会引起误判。但是结合趋势项和去趋势项分析可知,将趋势项的排列熵作为属性1,去趋势项的排列熵作为属性2,即可有效概括不同尺度上的故障信息,从而完成对滚动轴承故障信号特征分量的提取。为验证SPA-PE作为特征提取方法的有效性,选用PE特征提取及EMD-PE特征提取进行对比分析;同时,为了说明PSO算法对SVM的优化效果,每种方法均与未使用优化算法的SVM分类器进行对比。其中标签1,标签2,标签3,标签4分别对应正常状态、内圈故障、滚动体故障及外圈故障。

直接对滚动轴承故障信号进行PE解算,并将特征向量输入至SVM和PSOSVM分类器中,结果如图8所示。

采用滚动轴承故障信号的PE作为特征向量,针对4种状态160个测试集,PE-SVM的故障诊断精度为84.375%(135/160);PE-PSOSVM的故障诊断精度



(a) SVM diagnosis results



(b) PSOSVM diagnosis results

Fig. 8 PE diagnosis results


为 87.5%(140/160)。其中,PSO 优化 SVM 惩罚因子为 1.8232,核参数为 645.2294。

继续验证 EMD-PE 算法对滚动轴承故障信号的诊断效果。首先对滚动轴承故障信号进行 EMD 分解,然后采用前 6 个 IMF 分量的排列熵值作为特征向量,将特征向量输入至 SVM 和 PSOSVM 分类器中,结果如图 9 所示。


针对 4 种状态 160 个测试集,采用 EMD-PE-SVM 算法的故障诊断精度为 95%(152/160);采用 EMD-PE-PSOSVM 的故障诊断精度为 96.875%(155/160)。其中,PSO 优化 SVM 惩罚因子为 13.2931,核参数为 1960.7666。

采用本文所提出的 SPA-PE-PSOSVM 方法进行故障诊断,首先对滚动轴承故障信号进行 SPA 分解,得到趋势项和去趋势项,然后分别计算 PE 值作为特征向量,将特征向量输入至 SVM 和 PSOSVM 分类器中,结果如图 10 所示。

针对 4 种状态 160 个测试集样本,采用 SPA-PE-



(a) SVM diagnosis results



(b) PSOSVM diagnosis results

Fig. 9 EMD-PE diagnosis results

SVM 算法的故障诊断精度为 96.875%(155/160);采用 SPA-PE-PSOSVM 的故障诊断精度为 100%(160/160)。其中,PSO 优化 SVM 惩罚因子为 0.1,核参数为 91.073。

验证 1:为了直观说明对滚动轴承振动信号的故障诊断效果,将各方法所得结果列于表 1 所示。表中数值表示针对每一个状态下的 40 个测试集样本,采用分类算法所得到的正确分类结果数目。表中 ACC 表示精度的英文简写。

如表 1 所示,采用粒子群优化算法的 PE,EMD-

Table 1 Accuracy rate comparison of six algorithm

Methods	NORM	IRF	REF	ORF	ACC/%
PE-SVM	40	39	35	21	84.375
PE-PSOSVM	40	37	38	25	87.5
EMD-PE-SVM	40	38	40	34	95
EMD-PE-PSOSVM	40	39	40	36	96.875
SPA-PE-SVM	40	40	35	40	96.875
SPA-PE-PSOSVM	40	40	40	40	100




Fig. 10 SPA-PE diagnosis results

PE, SPA-PE 三种方法相比默认参数的故障诊断算法而言,精度分别提高了 3.125%, 1.875%, 3.125%, 证明了在参数选择方面采用 PSO 优化 SVM 参数能够有效提高故障诊断准确性。相比直接对滚动轴承故障信号求取 PE 值而言,采用 EMD-PE 及 SPA-PE 这种多尺度分解算法均能有效提高故障诊断能力;而在多尺度分解方面,SPA-PE 方法较 EMD-PE 方法而言具有更高的精度优势,且 SPA-PE 方法所需的运算量小(仅需计算趋势项与去趋势项的 PE),算法简单。通过实验分析,证明了本文所提出的 SPA-PE-PSOSVM 算法的有效性。

验证 2:为了进一步分析本文所提出的 SPA-PE-PSOSVM 算法的有效性,在选择的实验数据基础上,分别选取不同比例(总样本数量的 10%, 20%, 30%, 40%)的数据作为训练集,其余样本作为测试集(例如 10% 即选择 4 种状态下各 80 组数据中的 8 组作为训练集(10%),余下 72 组作为测试集(90%))。采用 EMD-PE-PSOSVM 算法与 SPA-PE-PSOSVM 算法进

行对比,在不同训练集下所得结果如表 2 所示。

Table 2 Classification results under different training samples

Methods	Train/%	NORM	IRF	REF	ORF	ACC/%
EMD	10	71	69	72	61	94.79
	20	64	62	64	60	97.65
	30	56	55	56	52	97.76
	40	48	46	48	44	96.87
SPA	10	72	66	72	66	95.83
	20	63	64	64	63	99.22
	30	56	56	56	56	100
	40	48	48	48	48	100

如表 2 所示,当训练集数目减少时,SPA-PE-PSOSVM 方法的故障诊断精度有着一定程度的降低,但总体优于 EMD-PE-PSOSVM 方法;且在 30%, 40% 训练集基础上仍具有 100% 的诊断精度,进一步论证了 SPA 分解在多尺度分析中的优势。

4 结 论

本文结合 SPA 分解方法进行轴承信号多尺度分析,同时通过排列熵算法进行特征提取,并将其应用于轴承故障数据诊断。实验结果表明:

(1)采用 SPA 方法进行多尺度分解,所得分量个数(2 个)远小于 EMD 分解方法,避免了特征量选取的冗余性,提高了算法的简洁程度;同时,SPA 方法所得的趋势项和去趋势项更好地反映了不同尺度的特征信息,具有更好的故障诊断精度,在实验中精确度为 100%。

(2)采用粒子群优化算法的 PE, EMD-PE, SPA-PE 三种方法相比默认参数的故障诊断算法而言,精度分别提高了 3.125%, 1.875%, 3.125%。PSO 方法可以更加准确地选取 SVM 训练过程中的惩罚因子和核参数,提高了 SVM 的分类能力。

(3)SPA 算法流程简单,计算量较小,后续可根据其算法特性考虑将其应用于去噪滤波等信号分析方面。

致 谢:感谢山东省自然科学基金面上项目和国防科技项目基金的资助。

参考文献

- [1] 张 赞, 杨 栋, 斯彦刚, 等. 基于监督流形学习的航空发动机振动故障诊断方法[J]. 推进技术, 2017, 38(5): 1147-1154. (ZHANG Yun, YANG Dong, SI Yan-gang, et al. Aero-Engine Vibration Fault Diagnosis

- Based on Supervised Manifold Learning[J]. *Journal of Propulsion Technology*, 2017, 38(5): 1147-1154.)
- [2] 费成巍, 白广忱. 基于WCFSE-FSVM的转子振动故障诊断方法[J]. 推进技术, 2013, 34(9): 1266-1271. (FEI Cheng-wei, BAI Guang-chen. Rotor Vibration Fault Diagnosis Method Based on WCFSE-FSVM[J]. *Journal of Propulsion Technology*, 2013, 34(9): 1266-1271.)
- [3] 李晓娟, 曲建岭, 邹文栋, 等. 航空发动机状态参数的关联维数分析[J]. 计算机仿真, 2013, 30(9): 56-59.
- [4] 李兵, 张培林, 任国全, 等. 形态学广义分形维数在发动机故障诊断中的应用[J]. 振动与冲击, 2011, 30(10): 208-211.
- [5] 侯荣涛, 闻邦椿, 周 飙. 基于现代非线性理论的汽轮发电机组故障诊断技术研究[J]. 机械工程学报, 2005, 41(2): 142-147.
- [6] Yan R, Gao R X. Approximate Entropy as a Diagnostic Tool for Machine Health Monitoring[J]. *Mechanical Systems and Signal Processing*, 2007, 21(2): 824-839.
- [7] 艾延廷, 付 琪, 田 晶, 等. 基于融合信息熵距的转子裂纹-碰摩耦合故障诊断方法[J]. 航空动力学报, 2013, 28(10): 2161-2166.
- [8] 费成巍, 白广忱, 李晓颖. 基于过程功率谱熵SVM的转子振动故障诊断方法[J]. 推进技术, 2012, 33(2): 293-298. (FEI Cheng-wei, BAI Guang-chen, LI Xiaoying. Method of Rotor Vibration Fault Diagnosis from Process Power Spectrum Entropy and SVM[J]. *Journal of Propulsion Technology*, 2012, 33(2): 293-298.)
- [9] Christoph B, Bernd P. Permutation Entropy: A Natural Complexity Measure for Time Series[J]. *Physical Review Letters*, 2002, 88(17).
- [10] 袁 明, 罗志增. 基于排列组合熵的表面肌电信号特征分析[J]. 杭州电子科技大学学报, 2012, 32(1): 64-67.
- [11] Yan R, Liu Y, Gao R X. Permutation Entropy: A Non-linear Statistical Measure for Status Characterization of Rotary Machines [J]. *Mechanical Systems and Signal Processing*, 2012, 29: 474-484.
- [12] Moore K J, Kurt M, Eriten M, et al. Wavelet-Bounded Empirical Mode Decomposition for Measured Time Series Analysis[J]. *Mechanical Systems and Signal Processing*, 2018, 99: 14-29.
- [13] 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 of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences*, 1998, 454 (1971): 903-995.
- [14] 俞 啸, 范春阳, 董 飞, 等. 基于EMD与深度信念网络的滚动轴承故障特征分析与诊断方法[J]. 机械传动, 2018, 42(6): 157-163.
- [15] Chen X, Cui B. Efficient Modeling of Fiber Optic Gyroscope Drift Using Improved EEMD and Extreme Learning Machine[J]. *Signal Processing*, 2016, 128: 1-7.
- [16] 边 杰. 基于遗传算法参数优化的变分模态分解结合1.5维谱的轴承故障诊断[J]. 推进技术, 2017, 38(7): 1618-1624. (BIAN Jie. Fault Diagnosis of Bearing Combining Parameter Optimized Variational Mode Decomposition Based on Genetic Algorithm with 1.5-Dimensional Spectrum[J]. *Journal of Propulsion Technology*, 2017, 38(7): 1618-1624.)
- [17] 石志标, 陈 斐, 曹丽华. 基于排列熵与IFOA-RVM的汽轮机转子故障诊断[J]. 振动与冲击, 2018, 37(5): 79-84.
- [18] Yang Q, Ba C, Li C, et al. An Ensemble Fault Diagnosis Approach for Multimodal Process[C]. *Xiamen: 2017 IEEE International Conference on Signal Processing, Communications and Computing*, 2017.
- [19] 郑近德, 程军圣, 杨 宇. 基于LCD和排列熵的滚动轴承故障诊断[J]. 振动.测试与诊断, 2014, 34(5): 802-806.
- [20] 周念成, 王予疆, 陈 刚, 等. 低频振荡模式辨识中信号非线性去趋的平滑先验方法[J]. 电力系统保护与控制, 2012, 40(11): 1-5.
- [21] 黄海峰, 易 武, 易庆林, 等. 滑坡位移分解预测中的平滑先验分析方法[J]. 水文地质工程地质, 2014, (5): 95-100.
- [22] Bandt C. Permutation Entropy and Order Patterns in Long Time Series [M]. *San Francisco: Time Series Analysis and Forecasting, Springer International Publishing*, 2016.
- [23] Wu S, Wu P, Wu C, et al. Bearing Fault Diagnosis Based on Multiscale Permutation Entropy and Support Vector Machine[J]. *Entropy*, 2012, 14(8): 1343-1356.
- [24] Wang X Y, Liang L L, Li W Y, et al. A New SVM-based Relevance Feedback Image Retrieval Using Probabilistic Feature and Weighted Kernel Function[J]. *Journal of Visual Communication & Image Representation*, 2016, 38: 256-275.
- [25] Gonzalo E, Fernandezluna J, MartInez J L. A Brief Historical Review of Particle Swarm Optimization (PSO) [J]. *Journal of Bioinformatics & Intelligent Control*, 2012, 1(1): 3-16.

(编辑:史亚红)