

控制与决策

Control and Decision

一种参数优化VMD多尺度熵的轴承故障诊断新方法

黄大荣, 柯兰艳, 林梦婷, 孙国玺

引用本文:

黄大荣, 柯兰艳, 林梦婷, 等. 一种参数优化VMD多尺度熵的轴承故障诊断新方法[J]. *控制与决策*, 2020, 35(7): 1631–1638.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2018.1598>

您可能感兴趣的其他文章

Articles you may be interested in

[基于节点优化型DAG-LDM的机组滚动轴承故障诊断方法](#)

Fault diagnosis method of wind turbine rolling bearing based on node optimized DAG-LDM

控制与决策. 2019, 34(7): 1394–1400 <https://doi.org/10.13195/j.kzyjc.2017.1657>

[基于多块相对变换独立主元分析的故障诊断方法](#)

Fault diagnosis approach based on relative transformation ICA of multiblock

控制与决策. 2018, 33(11): 2009–2014 <https://doi.org/10.13195/j.kzyjc.2017.0869>

[基于主元和判别集分析的模拟电路故障诊断](#)

Fault diagnosis of analog circuit by integrating principal component analysis with linear discriminant analysis

控制与决策. 2015(7): 1321–1324 <https://doi.org/10.13195/j.kzyjc.2014.0774>

[基于模糊粗糙集和支持向量机的化工过程故障诊断](#)

Fault diagnosis of chemical industry process based on FRS and SVM

控制与决策. 2015(2): 353–356 <https://doi.org/10.13195/j.kzyjc.2014.0246>

[基于MultiBoost的集成支持向量机分类方法及其应用](#)

MultiBoost with SVM-based ensemble classification method and application

控制与决策. 2015(1): 81–85 <https://doi.org/10.13195/j.kzyjc.2013.1562>

一种参数优化 VMD 多尺度熵的轴承故障诊断新方法

黄大荣^{1†}, 柯兰艳¹, 林梦婷¹, 孙国玺²

(1. 重庆交通大学 信息科学与工程学院, 重庆 400074; 2. 广东石油化工学院
广东石油化工装备故障诊断重点实验室, 广东 茂名 525000)

摘要: 现有基于变分模态分解算法(VMD)的轴承故障诊断方法,由于其参数 K 需要依据先验知识预先设定,缺乏对 K 值最优设定的理论支撑,难以保证故障特征提取及故障诊断的精确性. 针对上述问题,提出一种基于参数估计优化的 VMD 与多尺度熵(MSE)的石化装备轴承特征提取及诊断新方法. 首先,针对 VMD 分解参数 K 的难以实现最优设定问题,利用局部均值分解(LMD)自适应分解分量的频率分布特征,构建一种实现 K 值有效估计的方法;其次,在 VMD 分解的基础上,提出一种 MSE 和线性判别分析(LDA)协同特征提取方法,完成特征模型构建;然后,针对轴承故障特征样本过少,利用支持向量机(SVM)对提取故障特征进行识别;最后,利用石化装备实验室仿真平台的轴承故障数据进行实验,验证算法的有效性和工程实用性. 对比分析表明,所提出的算法可以很好地提取故障特征且故障识别精度较高,具有较好工程操作性和扩展性.

关键词: 轴承故障; 变分模态分解算法; 多尺度熵算法; 线性判别分析算法; 支持向量机故障特征识别

中图分类号: TP273

文献标志码: A

A new fault diagnosis approach for bearing based on multi-scale entropy of the optimized VMD

HUANG Da-rong^{1†}, KE Lan-yan¹, LIN Meng-ting¹, SUN Guo-xi²

(1. College of Information Science and Engineering, Chongqing Jiaotong University, Chongqing 400074, China;
2. Guangdong Provincial Key Laboratory of Petrochemical Equipment Fault Diagnosis, Guangdong University of Petrochemical Technology, Maoming 525000, China)

Abstract: It is well known that the parameter K of variational mode decomposition (VMD) needs to be preset according to prior knowledge without theoretical support for optimal setting. Thus, for the existing fault diagnosis methods for bearing based on VMD, the correctness of characteristic extraction and accuracy of fault diagnosis are extremely difficult to be guaranteed. To solve this problem, a novel collaborative diagnosis approach of petrochemical equipment for bearing based on optimal VMD and multiscale entropy (MSE) is proposed. Firstly, because optimizing the decomposition parameter K for VMD is difficult, an effective estimation model of K is constructed according to the frequency distribution characteristics of the decomposition components of local mean decomposition (LMD). Then, a novel characteristic extraction technique collaborating MSE and linear discriminant analysis (LDA) is proposed to establish characteristic samples. Furthermore, aiming at the fault characteristic of small samples for bearing, support vector machine (SVM) is introduced to identify the fault characteristics. Finally, the bearing fault data collected from the simulation platform of the petrochemical equipment laboratory is used to verify the effectiveness and engineering practicability of the proposed approach. The comparative analyses show that the proposed algorithm can effectively diagnose faults of the bearing with good engineering operability and scalability.

Keywords: bearing faults; VMD algorithm; MSE algorithm; LDA algorithm; SVM fault characteristics recognition

收稿日期: 2018-11-19; 修回日期: 2019-03-03.

基金项目: 国家自然科学基金项目(61663008, 61573076, 61473094, 61304104, 61004118); 教育部留学归国人员科研启动基金项目(2015-49); 重庆市高等学校优秀人才支持计划项目(2014-18); 广东省石化装备故障诊断重点实验室开放式基金项目(GDUPKLAB201501/GDUPKLAB201604); 广东省普通高校特色创新项目(201463104); 重庆市教委科学技术研究项目(KJ1705139/KJZD-K201800701).

责任编辑: 姜斌.

[†]通讯作者. E-mail: hcx1978@163.com.

0 引言

滚动轴承作为保证机械设备正常运行的关键部件之一,对其运行状态的安全监控一直是工业界和学术界的重点和难点.随着社会不断向前发展,石化装备也日趋复杂化,因而对轴承状态监测提出更高的要求.然而,由于设备本身和实际工况的复杂性,使得轴承故障振动信号具有较高的随机性和复杂性,导致故障特征难以正确提取,给轴承运行状态的安全监控造成了极大困难.因此,针对轴承故障采取合理的方法进行故障特征提取及诊断,以保证轴承故障诊断及安全监控的精确性,受到国内外学者的极大重视^[1-3].

近年来,针对复杂设备的轴承故障诊断问题,相关学者已进行了大量的探索并取得了丰富的成果.总体上,轴承故障诊断方法分为基于信号处理方法和人工智能方法^[4-5].其中,基于信号处理的诊断方法由于其直观性、计算简单性及工程实用性被广泛使用.作为信号处理方法中最常用的算法,经验模态分解(EMD)具有处理非线性、非平稳信号的独特优势,是诊断轴承故障的一种重要技术手段^[6-7].但遗憾的是,EMD方法本质上是一个二进制滤波器组,这种信号频域分割特性使得EMD方法在处理轴承故障信号时存在模态混淆和端点效应弊端^[8].为此,有学者提出局部均值分解(local mean decomposition, LMD)算法,可很好地改善EMD所遗留的缺陷,有效地处理非线性、非平稳信号,保证故障特征提取正确性^[9-11].但值得注意的是,LMD仍然是递归模态分解,受采样频率影响较大,难以保证分解精度^[12].为解决EMD和LMD受限于递归模态分解框架的问题,Dragomireskiy等^[13]在2014年提出变分模态分解算法(variational mode decomposition, VMD),此算法采用一种非递归的处理技术对信号进行分解,完美地弥补了循环递归筛分的缺陷,从而有效地避免了LMD及EMD的端点效应和模态混淆束缚.实际上,VMD算法虽然克服了EMD及LMD算法的端点效应和模态混淆问题,但是VMD分解精度较大程度上取决于其分解参数 K (分解分量个数).因此, K 值选取的正确性是保证VMD分解精度的首要前提.为探索 K 值的选取方法,有学者提出利用EMD分解后的分量频率分布对 K 值进行估计^[14].此方法虽然可完成 K 值粗略估计,但由于EMD具有较为严重的端点效应和模态混淆,不可避免地会影响到 K 值估计结果,进而严重影响故障诊断精度.为此,本文提出利用LMD分量的频率分布特征对 K 值进行估计,以有

效解决VMD的 K 值难以最优选择问题.

考虑到实际工况的复杂,在完成参数 K 值估计的基础上,若只利用VMD分量的谱分析进行轴承故障诊断,则需要利用丰富人工经验进行判断,易对诊断结果造成极大干扰^[15-16].为避免直接利用谱分析引起误判现象,需进一步对分量进行特征提取并结合智能分类器进行特征识别.在特征表征方面,相比样本熵(Sp En)和近似熵(Ap En),多尺度熵(multiscale entropy, MSE)具有明显优势.MSE可全面反映信号的复杂度,能很好地区分不同故障,已被广泛应用到机械故障诊断领域^[17-18].

然而,由于轴承故障振动信号随机性较大,若只利用MSE对其进行特征样本构建,则会严重地影响诊断精度.同时,为克服因递归循环分解框架导致的抗扰性差和模态混淆等缺陷,本文协同MSE和VMD的优势,针对轴承故障振动信号非线性、非平稳的特点,构建一种基于VMD和MSE的特征向量提取及故障刻画方法.首先,利用LMD对轴承故障信号进行分解并利用其分量频率分布特征完成VMD分解参数 K 值的估计;其次,利用参数优化后的VMD对轴承信号进行分解;然后,考虑到实际工况的故障特征提取困难,基于MSE进行故障特征提取并利用线性判别分析(linear discriminant analysis, LDA)算法,进一步提高故障特征精度;最后,依托广东石化装备仿真平台,利用支持向量机(support vector machine, SVM)对本文构建的故障特征进行识别,验证所建立诊断模型的有效性和工程实用性.

1 轴承故障信号自适应分解模型

1.1 VMD分解原理

VMD分解是在2014年提出的一种新的自适应信号处理技术,利用变分分解框架能够很好地弥补EMD和LMD分解模态混淆及端点效应等不足,具有较高的分解精度.鉴于轴承故障振动信号非平稳、非线性的本质特征,本文利用VMD对轴承故障振动信号进行分解.

VMD分解将本征模态函数(intrinsic mode function, IMF)定义为一个调幅调频信号,即

$$u_k(t) = A_k(t) \cos[\phi_k(t)], \quad k = 1, 2, \dots, K. \quad (1)$$

其中: $A_k(t)$ 为 $u_k(t)$ 的瞬时幅值, $\omega_k = \phi'_k(t)$ 为 $u_k(t)$ 的瞬时频率, K 为分量个数.

设原信号 f 为多分量信号,由 K 个有限带宽的IMF分量 $u_k(t)$ 组成,且各IMF的中心频率为 ω_k .为确

定每个模态的带宽,通过如下步骤求取:

1) 求取模态函数的解析信号,对每个模态函数 $u_k(t)$ 进行希尔伯特变换,即

$$\left[\sigma(t) + \frac{j}{\pi t}\right] u_k(t). \quad (2)$$

2) 对各模态解析信号预估中心频率 $e^{-j\omega_k t}$ 进行混合,将每个模态的频谱调制到相应的基频带,如下所示:

$$\left[\left(\sigma(t) + \frac{j}{\pi t}\right) u_k(t)\right] e^{-j\omega_k t}. \quad (3)$$

3) 计算以上解调信号的梯度的平方 L^2 范数,估计出各模态分量的带宽. 建立约束变分模型为

$$\begin{aligned} \min_{\{u_k\}, \{\omega_k\}} & \left\{ \sum_k \left\| \partial_t \left[\left(\sigma(t) + \frac{j}{\pi t}\right) u_k(t)\right] e^{-j\omega_k t} \right\|_2^2 \right\}; \\ \text{s.t.} & \sum_k u_k(t) = f. \end{aligned} \quad (4)$$

其中: $u_k = \{u_1, u_2, \dots, u_K\}$ 表示分解得到的 K 个 IMF 分量, $\omega_k = \{\omega_1, \omega_2, \dots, \omega_K\}$ 表示各分量的中心频率.

为求解上述约束变分模型,引入二次惩罚因子 α 和 Lagrange 乘法算子 $\lambda(t)$,其中二次惩罚因子可在高斯噪声存在的情况下保证信号的重构精度, $\lambda(t)$ 使得约束条件保持严格性,扩展后的 Lagrange 表达式如下:

$$\begin{aligned} L(\{u_k(t)\}, \{\omega_k(t)\}, \lambda) = & \alpha \sum_k \left\| \partial_t \left[\left(\sigma(t) + \frac{j}{\pi t}\right) u_k(t)\right] e^{-j\omega_k t} \right\|_2^2 + \\ & \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_k u_k(t) \right\rangle. \end{aligned} \quad (5)$$

利用乘子交替方向算法不断更新各 IMF 及其中心频率,最终所求式(4)的鞍点即为原问题的最优解. 因此,所有频域中的 IMF 可通过下式获得:

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2}, \quad (6)$$

其中 $\hat{u}_k^{n+1}(\omega)$ 为当前剩余量 $\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega)$ 通过 Wiener 滤波的结果. 算法中各 IMF 功率谱的中心更新式如下:

$$\hat{\omega}_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k(\omega)|^2 d\omega}. \quad (7)$$

上述即是 VMD 的自适应分解过程. 从分解原理上看, VMD 很好地规避了 EMD 及 LMD 算法的端点效应和模态混淆. 但从实际分解过程看, VMD 却丧失了 EMD 和 LMD 的自主分解信号的能力, VMD 需要预先设定 K 值,且 K 值的合理设定决定了 VMD 分

解精度. 现有预估方法往往根据先验知识,缺乏理论依据,难以真正保证故障信号分解精度,易造成虚假冲击分量,影响故障诊断精度. 为此,寻找一种合理的 K 值的估计算法是保证 VMD 分解精度的关键前提.

1.2 VMD的分解分量 K 值估计

VMD 分解信号时, K 值的选择决定了整个分解的准确性,故 K 值选择是保证分解精度的首要前提. 文献 [13] 基于 EMD 对 K 值进行估计,但由于 EMD 本身弊端导致对 K 值估计不准确. LMD 是在 EMD 基础上提出的一种改进算法,在一定程度上改善了 EMD 存在的问题. 更重要的是,其分解过程中无需信号的先验知识,完全由数据自身驱动,本征模态函数自适应地从原信号中分解得到. 因此,利用 LMD 此特性评估原始信号包含的有效模态数,以此作为 VMD 算法中 K 的最优估计值,保证 VMD 分解精度.

设原始信号为 f ,被 LMD 分解如下:

$$f(t) = \sum_{p=1}^M \text{PF}_p(t) + r_M(t), \quad (8)$$

其中 M 为分解的 PF 分量个数.

在此基础上,定义 K 值估计规则如下:

引理 1 若所有 $\text{PF}_i (i = 1, 2, \dots, M)$ 频谱中包含独立不重复的频率冲击为 N 个,则 VMD 中 K 值的估计值为 N .

2 基于MSE和LDA的故障特征提取模型

在 VMD 完成故障信号分解的基础上,对前 q 个分量 $u_k(t) (k = 1, 2, \dots, q)$ 进行特征初步提取并进行特征优化. 基于 MSE 和 LDA 的故障特征提取框架如图 1 所示.

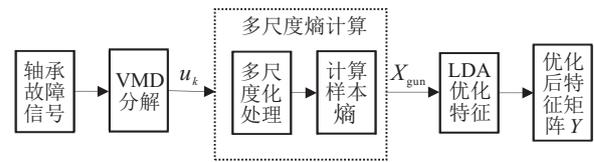


图 1 轴承故障特征提取框架

2.1 基于MSE初步特征提取

MSE 用于描述时间序列在多个时间尺度上的复杂性,它的基础是样本熵,而样本熵可以看作是近似熵的改进.

MSE 计算步骤如下所示:

1) 输入信号为 VMD 分解的信号 u_k , 对此信号作粗粒化变换,得到新的序列为

$$\begin{aligned} y_{n_i}(\tau) &= \frac{1}{\tau} \sum_{i=(j-1)\tau+1}^{j\tau} u_k(i), \\ j &= 1, 2, \dots, \frac{L}{\tau}, k = 1, 2, \dots, q. \end{aligned} \quad (9)$$

其中: L 表示信号长度, τ 表示尺度因子, u_k 信号被分割成 τ 段且每段长为 L/τ 的粗粒序列.

2) 给定模式维数 m 和相似容限 $r (r > 0)$, 形成 m 维向量为

$$U_m(i) = (yn_i(\tau), yn_{i+1}(\tau), \dots, yn_{i+m-1}(\tau)), \\ i = 1, 2, \dots, L - m. \quad (10)$$

3) 计算 $U_m(i)$ 与 $U_m(j)$ 间距离

$$d_{ij} = d(U_m(i), U_m(j)) = \\ \max |U_m(i+v) - U_m(j+v)|, \\ v = 1, 2, \dots, m, j = 1, 2, \dots, L - m + 1 \text{ 且 } i \neq j. \quad (11)$$

4) 统计 $U_m(i)$ 与 $U_m(j)$ 间距离小于 r 的个数 G , 并与总数 $L - m + 1$ 作比, 即

$$C_m(i) = \frac{G}{L - m + 1}. \quad (12)$$

5) 计算 $C_m(i)$ 的均值, 即

$$\Phi_m(i) = \frac{1}{L - m + 1} \sum_{i=1}^{L-m+1} C_m(i). \quad (13)$$

6) $m \rightarrow m + 1$, 重复步骤 1) ~ 步骤 5) 计算 $\Phi_{m+1}(i)$.

7) 计算样本熵估计值, 即

$$\text{SampEn}(m, r, L) = -\ln \frac{\Phi_{m+1}}{\Phi_m}. \quad (14)$$

重复上述步骤, 可得不同尺度上的样本熵值, 即为 MSE. 令由每种轴承状态下的前 q 个分量的 MSE 组成的特征矩阵为 $X_{g \times n}$, 其中 g 为轴承故障样本个数, n 为选取 VMD 分解分量个数, 即 $n = q$.

经过 VMD 分解和 MSE 的特征提取后, 此特征向量可以一定程度上区别轴承的各种状态. 但从实际信号中提取出来的特征通常具有冗余性和高维性的特点, 若将 MSE 特征直接用于轴承的故障诊断, 则可能会导致诊断精度较低, 故需寻求一种特征优化算法对特征进行进一步优化.

2.2 LDA 故障特征优化

在特征优化算法中, LDA 方法运用 Fisher 判别准则, 具有聚拢同一模式的样本聚在一起, 分开不同模式的样本的能力, 故常被运用于特征优化^[19-20]. 据此, 采用 LDA 方法对 MSE 特征进行降维抽取, 以获得新的最优特征.

假设特征矩阵 $X_{g \times n}$ 由上述提取的故障多尺度熵组成, 故 $X_{g \times n} = (x^{(1)}, x^{(2)}, \dots, x^{(g)})^T$, 其中 $x^{(i)} = (x_1^{(i)}, x_2^{(i)}, \dots, x_n^{(i)})$.

定义类内离散度矩阵为

$$S_w = \sum_{j=1}^c \sum_{i=1}^{n_j} (x_i^j - \text{me}_j)(x_i^j - \text{me}_j)^T. \quad (15)$$

其中: c 表示故障种类, x_i^j 表示第 j 类的第 i 个向量, me_j 表示第 j 类的样本均值, 表示为

$$\text{me}_j = \frac{1}{g_j} \sum_{i=1}^{g_j} x_i^j, \quad j = 1, 2, \dots, n. \quad (16)$$

定义类间离散度矩阵为

$$S_b = \sum_{j=1}^c (\text{me}_j - \text{Me})(\text{me}_j - \text{Me})^T, \quad (17)$$

其中 Me 表示总体样本均值.

设故障特征 $X_{g \times n}$ 降维投影矩阵为

$$W_{n \times d} = \begin{bmatrix} w_{11} & w_{12} & \dots & w_{1n} \\ w_{21} & w_{22} & \dots & w_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ w_{d1} & w_{d2} & \dots & w_{dn} \end{bmatrix}. \quad (18)$$

其中: d 表示降维的目标维数, 一般设置为 2 或者 3^[21]; $W_{n \times d}$ 通过 Fisher 准则求取.

为保证 $W_{n \times d}$ 是保证特征提取的最佳投影特征, 定义求取规则如下.

引理 2 使类间散度 $W^T S_b W$ 最大, 类内散度 $W^T S_w W$ 最小的投影特征即最佳投影特征.

规则定义如下:

$$J(W) = \arg \max \frac{|W^T S_b W|}{|W^T S_w W|}. \quad (19)$$

式(19)表明, 最佳降维矩阵 $W_{n \times d}$ 对应 $J(W)$ 特征值最大的特征矩阵.

设轴承故障多尺度熵特征向量 $X_{g \times n}$ 经过最佳投影向量 $W_{n \times d}$ 后的特征矩阵为 Y , 即

$$Y = X_{g \times n} W_{n \times d}. \quad (20)$$

3 基于支持向量机轴承故障特征识别

由于在实际诊断过程中, 利用 MSE 及 LDA 特征提取模型得到的故障特征样本较少, 传统的 BP 神经网络等分类器针对小样本数据无法取得理想的分类精度. 在此情况下, SVM 作为分类器中的新生力量, 针对小样本条件下的非线性映射具有独特的优势, 而且能限制过学习, 非常适合小样本. 因此, 选取 SVM 进行对故障特征向量 Y 进行识别. 首先, 在对 SVM 原理分析基础上, 构建合适的 SVM 分类器, 完成故障特征识别框架的构建.

3.1 SVM 分类原理

设训练集合为 $X_{un} = \{y_i, \text{la}_i, i = 1, 2, \dots, l\}$, 每个样本 $y_i \in R^d$ 属于一个类别, la_i 表示分类标签.

分类曲线表示为 $a \times y + b = 0$, 其中 a 表示权重向量, b 为阈值, 故分类函数构造为

$$O(y) = \text{sgn}(ay + b) = \text{sgn}\left\{\sum_{i=1}^l \alpha_i \text{la}_i(y, y_i) + b\right\}. \quad (21)$$

$$\begin{cases} \max \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j \text{la}_i \text{la}_j(y_j, y_i); \\ \text{s.t. } \alpha_i \geq 0, \sum_{i=1}^l \alpha_i \text{la}_i = 0. \end{cases} \quad (22)$$

式(22)中 α_i 不为0的样本 y_i 即为支持向量. 其中阈值和权值分别为 $b = \text{la}_i - a \cdot y_i$ 和 $a = \sum_{i=1}^l \alpha_i \text{la}_i y_i$.

针对非线性分类, 通过非线性映射 $\varphi: R^n \rightarrow F$, $y \rightarrow \varphi(y)$ 将原始空间 R^n 的样本映射到高维线性可分空间 F , 故待分样本为 $\{\varphi(y_1), \varphi(y_2), \dots, \varphi(y_n)\}$. 通过引入核函数 $K(y_i, y_j)$ 解决 φ 难以求解的问题, 最优分类面表示如下:

$$O(y) = \sum_{i=1}^n \alpha_i \text{la}_i \langle \varphi(y_i), \varphi(y) \rangle + b = \sum_{i=1}^n \alpha_i \text{la}_i K(y_i, y) + b. \quad (23)$$

3.2 基于SVM故障特征识别

一类对余类(one versus rest, OVR)是SVM处理多分类问题时, 实现多类分类器的最早出现且目前运用最广的一种策略. 本文选取OVR对轴承故障特征进行识别, 从而达到故障诊断效果.

在故障信号经过VMD分解、MSE特征提取及LDA特征优化基础上, 设计轴承故障诊断具体步骤如下.

step 1: 利用LMD对轴承振动信号进行分解得到相应的PF分量, 并利用PF分量的频谱冲击分量估计VMD分解算法中参数 K , 如引理1.

step 2: 在参数 K 被估计的基础上, 利用VMD对原故障信号进行分解, 得到分解分量 u_k .

step 3: 利用MSE对step 2中前 q 个 u_k 进行初步特征提取, 如式(9)~(14), 并利用LDA对特征进一步约简优化, 得到最终故障特征 Y , 如式(20).

step 4: 若故障类别为 c 类, 则构造 c 个两类分类机, 其中, 第 i 个分类机会将第 i 类同余下的各类区分.

step 5: 构造样本数据, 将故障特征 Y 分成训练数据 Y_1 和测试数据 Y_2 . 设第 i 个分类机训练时, 选取第 i 类为正类, 其余类为负类, 训练式如下:

$$f(Y) = \max(\Omega_i Y_{1i} - b_i). \quad (24)$$

其中: Ω_i 为权系数, Y_{1i} 为输入训练特征数据, b_i 为偏差量.

step 6: 利用step 5中训练好的权系数 Ω_i 及偏差量 b_i , 输入测试数据 Y_{2i} , 由下式可得到训练数据输出结果:

$$g_i(Y) = \Omega_i Y_{2i} - b_i. \quad (25)$$

step 7: 利用step 6中测试得到的结果, 比较每个分类机 $g_i(Y)$, 若第 i 个分类机的 $g_i(Y)$ 最大, 则测试数据应该为第 i 类.

本文设计的轴承诊断方法诊断流程如图2所示.

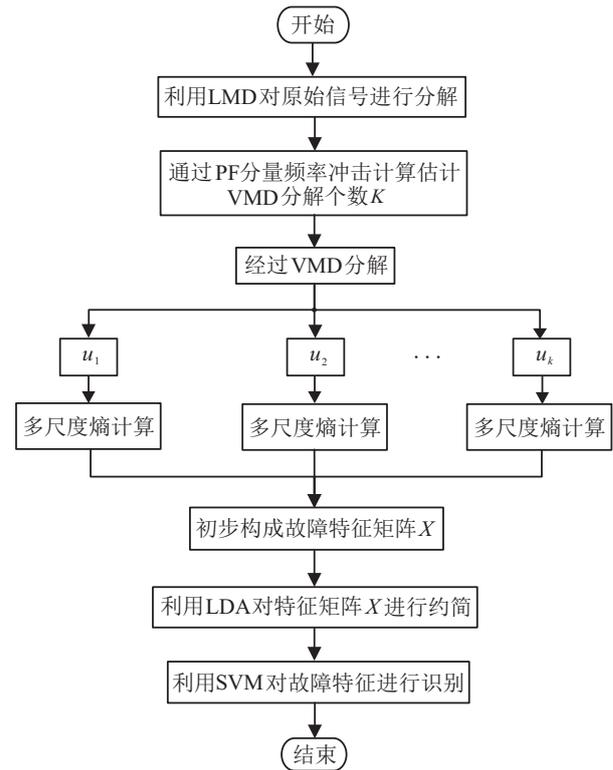


图2 轴承故障特征提取框架

4 实例验证

为验证本文方法的有效性和实用性, 依托广东石油化工学院故障诊断重点实验室的实验平台, 以10万吨顺丁橡胶装置挤压机及膨胀干燥机的轴承数据作为本文研究对象, 主要包括正常、外裂和内裂3种数据. 本次实验数据采集基站系统总体设计如图3所示.



图3 轴承故障信号采集基站

基于此采集基站,本次实验的轴承型号为NSK NN3021,其中NSK NN3021实验轴承故障配件如图4所示.在此实验平台上设计轴承正常、外裂和内裂3种状态,在这3种状态下采集得到每种故障数据大小为 50×1024 .

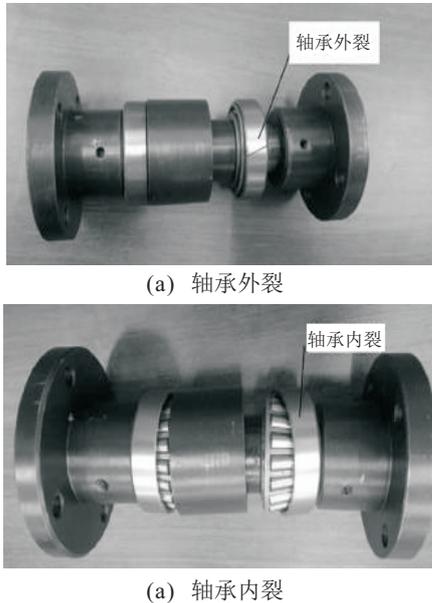


图4 轴承故障信号采集设备

4.1 基于LMD分解的VMD参数估计

利用LMD分解对VMD参数进行估计时,以一组外裂故障数据为例.在实验仿真中,通过分析LMD的前4个分量的频谱,估计原始信号中独立频率分量个数,完成VMD分解参数 K 的估计.

由图5可看出,第2个分量频率成分几乎与第1个分量一致,而第3个与第4个一致,判定独立频谱分量为4个,故设定VMD分解分量 $K = 4$.

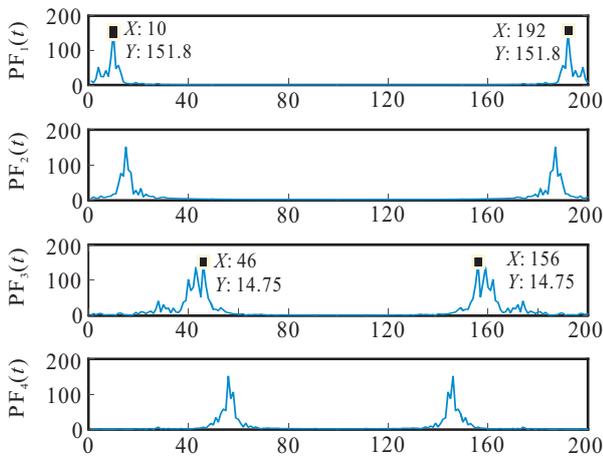


图5 PF分量频谱结果

4.2 LDA特征降维

经过VMD分解后,选择前4个分量进行MSE计算,初步构建故障特征矩阵 $X_{150 \times 4}$,并利用LDA对特

征进行降维.本文设置降维目标 $d = 2$,得到如下仿真结果.其中仿真特征矩阵如下:

$$\lambda = \begin{bmatrix} 8.5114 & 0 & 0 & 0 \\ 0 & 0.8960 & 0 & 0 \\ 0 & 0 & -0.0000 & 0 \\ 0 & 0 & 0 & -0.0000 \end{bmatrix},$$

故选取特征值最大的前两列作为投影向量,即

$$W_{n \times 2} = \begin{bmatrix} -0.784 & -0.227 \\ -0.569 & 0.066 \\ 0.218 & 0.069 \\ 0.110 & -0.968 \end{bmatrix}.$$

初步提取得到的特征矩阵 $X_{150 \times 4}$ 经过LDA优化为 $Y_{150 \times 2} = X_{150 \times 4} W_{4 \times 2}$,仿真结果如图6所示.

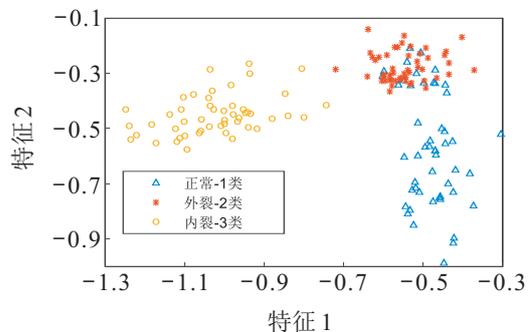


图6 LDA降维后特征分布

由图6可以发现,正常状态下的十几个特征点与外裂未区分开,其他故障特征都明显区分,验证了LDA对初始特征降维的有效性.

4.3 SVM特征识别

基于上述特征提取,共提取每种故障特征50组,随机抽取30组进行训练,剩余20组进行测试.SVM特征识别时,训练阶段和测试阶段的仿真结果分别如图7和图8所示.

由图7可知,训练数据共30组,包含3种状态(正常-1类,外裂-2类,内裂-3类).训练数据点共包括90个点,其中有6个点分类错误,故训练准确率为93.33%.

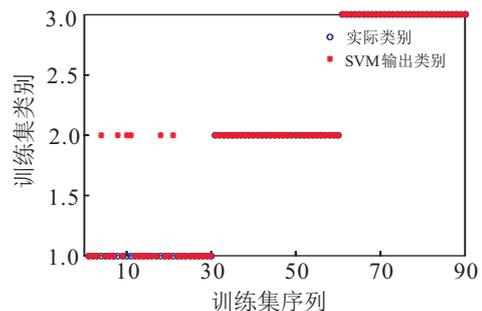


图7 SVM训练结果

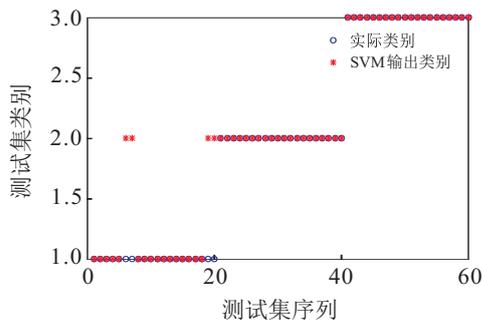


图8 SVM测试结果

由图8可以发现,20组数据的60个点中,有4个点分类错误,测试准确率为93.33%。

为进一步证明LMD对VMD参数估计的优越性(LVMD-MSE-LDA-SVM),在特征提取模型一致的前提下,设置EMD参数估计下的轴承诊断对比实验(EVMD-MSE-LDA-SVM)。此外,为证明LDA特征优化的正确性,在信号分解模型一致前提下,设置未进行LDA特征优化的轴承故障诊断对比实验(LVMD-MSE-SVM)。总结实验的测试和训练阶段故障诊断精度,如表1所示。

表1 对比实验轴承故障诊断精度 单位: %

| 训练/测试 | 训练正确率 | 测试正确率 | 总体正确率 |
|------------------|-------|-------|-------|
| LVMD-MSE-LDA-SVM | 93.33 | 93.33 | 93.33 |
| LVMD-MSE-SVM | 88.89 | 86.67 | 87.78 |
| EVMD-MSE-LDA-SVM | 64.44 | 66.67 | 65.56 |

由表1可知,利用本文方法进行故障诊断时,训练阶段正确率达到93.33%,测试阶段正确率达到93.33%,总体平均正确率达到93.33%,诊断精度高于其余3种诊断方法精度。对比结果一方面说明了LMD对VMD的K值估计准确性高于EMD,另一方面表明了LDA对特征优化的有效性。

5 结论

针对石化轴承装备复杂工况情况下,轴承故障诊断精度不高的问题,本文基于一种参数优化的VMD和MSE建立了一种轴承故障诊断新方法,以达到石化装备轴承故障诊断的目的。通过实例验证可得以下结论:

1) LMD对VMD的参数估计下的轴承诊断精度高于EMD参数估计下的诊断精度,验证了LMD对VMD参数估计更准确;

2) 利用LDA降维后的特征识别准确率高于直接利用MSE作为特征时的准确率,验证了LDA对特征的优化的有效性。

虽然基于本文方法取得了一定的诊断效果,但随

着设备的不断精细化,对信号分解精度要求更高,因此需进一步对VMD的二次惩罚因子进行优化,从而提高诊断精度,本文作者目前正在做这方面的研究,限于篇幅,将另文给出。

参考文献(References)

- [1] Luo H, Yang X, Krueger M, et al. A plug-and-play monitoring and control architecture for disturbance compensation in rolling mills[J]. IEEE/ASME Transactions on Mechatronics, 2018, 23(1): 200-210.
- [2] Luo H, Krueger M, Koenings T, et al. Real-time optimization of automatic control systems with application to BLDC motor test rig[J]. IEEE Transactions on Industrial Electronics, 2017, 64(5): 4306-4314.
- [3] Dong H, Wang Z, Ding S X, et al. On H -infinity estimation of randomly occurring faults for a class of nonlinear time-varying systems with fading channels[J]. IEEE Transactions on Automatic Control, 2016, 61(2): 479-484.
- [4] 文成林, 吕菲亚, 包哲静, 等. 基于数据驱动的微小故障诊断方法综述[J]. 自动化学报, 2016, 42(9): 1285-1299.
(Wen C L, Lv F Y, Bao Z J, et al. A review of data driven-based incipient fault diagnosis[J]. Acta Automatica Sinica, 2016, 42(9): 1285-1299.)
- [5] 刘朝华, 孟旭东, 陆碧良, 等. 基于节点优化型DAG-LDM的机组滚动轴承故障诊断方法[J]. 控制与决策, 2019, 34(7): 1394-1400.
(Liu Z H, Meng X D, Lu B L, et al. Fault diagnosis method of wind turbine rolling bearing based on a node optimized DAG-LDM[J]. Control and Decision, 2019, 34(7): 1394-1400.)
- [6] Tian K, Zhang T, Ai Y B, et al. Induction motors dynamic eccentricity fault diagnosis based on the combined use of WPD and EMD-simulation study[J]. Applied Sciences-basel, 2018, 8(10): 1-15.
- [7] Li Y, Xu M, Liang X, et al. Application of bandwidth EMD and adaptive multiscale morphology analysis for incipient fault diagnosis of rolling bearings[J]. IEEE Transactions on Industrial Electronics, 2017, 64(8): 6506-6517.
- [8] Yu X, Dong F, Ding E J, et al. Rolling bearing fault diagnosis using modified LFDA and EMD with sensitive feature selection[J]. IEEE Access, 2018, 99(6): 3715-3730.
- [9] Li Y, Liang X, Yang Y, et al. Early fault diagnosis of rotating machinery by combining differential rational spline-based LMD and K-L divergence[J]. IEEE Transactions on Instrumentation & Measurement, 2017,

- 99(11): 1-14.
- [10] Wang Z, Wang J, Kou Y, et al. Weak fault diagnosis of wind turbine gearboxes based on MED-LMD[J]. *Entropy*, 2017, 19(6): 1-15.
- [11] Shi Z L, Song W Q, Taheri S. Improved LMD, permutation entropy and optimized K -means to fault diagnosis for roller bearings[J]. *Entropy*, 2016, 18(3): 1-11.
- [12] Liu C, Cheng G, Chen X, et al. Planetary gears feature extraction and fault diagnosis method based on VMD and CNN[J]. *Sensors*, 2018, 18(5): 1-20.
- [13] Liu Y, Wang J, Li Y, et al. Feature extraction method based on VMD and MFDDFA for fault diagnosis of reciprocating compressor valve[J]. *Journal of Vibroengineering*, 2017, 19(8): 6007-6020.
- [14] Jiang X X, Shen C Q, Shi J J. Initial center frequency-guided VMD for fault diagnosis of rotating machines[J]. *Journal of Sound and Vibration*, 2018, 435: 36-55.
- [15] Huang D R, Ke L Y, Mi B, et al. A new incipient fault diagnosis method combining improved RLS and LMD algorithm for rolling bearings with strong background noise[J]. *IEEE Access*, 2018, 6(1): 26001-26010.
- [16] 尹进田, 谢永芳, 阳春华. 基于RVMD的牵引电机转子初期断条故障监测[J]. *控制与决策*, 2018, 33(3): 497-502.
(Yin J T, Xie Y F, Yang C H. Monitoring of incipient rotor bars broken fault in traction motors based on RVMD method[J]. *Control and Decision*, 2018, 33(3): 497-502.)
- [17] Tang G J, Wang X L, He Y L. A novel method of fault diagnosis for rolling bearing based on dual tree complex wavelet packet transform and improved multiscale permutation entropy[J]. *Mathematical Problems in Engineering*, 2016(6): 1-13.
- [18] Zheng J D, Jiang Z W, Pan H Y. Sigmoid-based refined composite multiscale fuzzy entropy and t -SNE based fault diagnosis approach for rolling bearing[J]. *Measurement*, 2018, 129: 332-342.
- [19] 黄大荣, 陈长沙, 孙国玺, 等. 复杂装备轴承多重故障的线性判别分析与反向传播神经网络协作诊断方法[J]. *兵工学报*, 2017, 38(8): 1649-1657.
(Huang D R, Chen C S, Sun G X, et al. Linear discriminant analysis and back propagation neural network cooperative diagnosis method for multiple faults of complex equipment bearings[J]. *Acta Armamentarii*, 2017, 38(8): 1649-1657.)
- [20] Bazdar A, Kazemzadeh R B, Niaki S T A. Fault diagnosis within multistage machining processes using linear discriminant analysis: A case study in automotive industry[J]. *Quality Technology & Quantitative Management*, 2017, 14(2): 1-16.
- [21] 肖迎群, 何怡刚, 刘继乾, 等. 基于主元和判别集成分析的模拟电路故障诊断[J]. *控制与决策*, 2015, 30(7): 1321-1324.
(Xiao Y Q, He Y G, Liu J Q, et al. Fault diagnosis of analog circuit by integrating principal component analysis with linear discriminant analysis[J]. *Control and Decision*, 2015, 30(7): 1321-1324.)

作者简介

黄大荣(1978—), 男, 教授, 博士生导师, 从事动态系统的故障诊断与容错控制、复杂系统的分析与设计等研究, E-mail: hcx1978@163.com;

柯兰艳(1992—), 女, 硕士生, 从事动态系统的故障诊断与容错控制、复杂系统的分析与设计的研究, E-mail: 15922758298@163.com;

林梦婷(1996—), 女, 硕士生, 从事动态系统的故障诊断与容错控制、复杂系统的分析与设计的研究, E-mail: 622170070012@mails.cqjtu.edu.cn;

孙国玺(1972—), 男, 教授, 从事控制算法、人工智能的研究, E-mail: guoxi.sun@gdupt.edu.cn.

(责任编辑: 孙艺红)