

基于 PF 能量特征和 SVM 的变速箱 轴承故障诊断方法

沈意平, 贺赛坪, 何宽芳, 李学军

(湖南科技大学 机械设备健康维护湖南省重点实验室, 湖南 湘潭 411201)

摘要:内圈点蚀、外圈压痕是变速箱滚动轴承常见典型故障,为实现其快速、准确诊断,提出基于局部均值分解(Local mean decomposition,简称LMD)的PF(Product Function)分量能量特征和支持向量机(Support Vector Machine,简称SVM)相结合的变速箱滚动轴承诊断方法.将采集的振动信号进行LMD局部均值分解,获得若干个PF分量,并以计算的PF分量的能量熵作为特征量输入支持向量机,进行滚动轴承的故障类型的识别.通过对滚动轴承正常状态、内圈点蚀故障和外圈压痕故障的诊断效果对比分析表明,相对于基于神经网络的轴承故障诊断方法,基于PF分量能量特征和支持向量机的诊断方法有着更高的故障识别率.

关键词:轴承;LMD;能量特征;支持向量机;故障诊断

中图分类号:TH-39

文献标志码:A

文章编号:1672-9102(2014)03-0019-05

Rolling bearing diagnosis based on PF energy feature and SVM

SHEN Yiping, HE Saiping, HE Kuanfang, LI Xuejun

(Hunan Provincial Key Laboratory of Health Maintenance for Mechanical Equipment,
Hunan University of Science and Technology, Xiangtan 411201, China)

Abstract: The inner ring erosion and outer indentation are typical faults of rolling bearing. In order to diagnose these faults rapidly and accurately, a novel diagnosis method of rolling bearing was proposed based on the energy characteristics of PF (Product Function) component and support vector machine (Support Vector Machine, SVM) by the vibration signal of local mean decomposition (Local mean decomposition, LMD). The collected vibration signals were decomposed into several PF components by the local mean decomposition, the calculated energy feature of the PF component were inputted to the support vector machine to identify the type of rolling bearing faults. The results show that the method has a high diagnosis and recognition rate for the typical faults of rolling bearing.

Key words: rolling bearing; energy feature; LMD; SVM; Fault Diagnosis

滚动轴承是变速箱传动装置的关键部件,运行中由于磨损、疲劳、腐蚀、过载等原因使得滚动轴承出现内圈点蚀、外圈压痕等故障,影响变速箱正常工作.变速箱滚动轴承故障诊断主要利用采集的变速箱敏感位置的振动信号,通过信号分析处理或根据故障特征信息的提取进行模式识别,实现轴

承故障类型、位置、程度等判别.

振动信号分析处理主要有时域、频域和时频分析方法,由于时频分析方法在分析非平稳信号有着明显的优势,目前已发展成为故障振动信号分析和特征提取的主要手段.常见的时频分析方法有短时傅里叶变换、Wigner分布、小波变换、EMD和

LMD^[1-4]. 其中 LMD 是 Jonathan 提出的一种新的自适应时频分析方法,该方法将一个复杂的多分量信号分解为若干个 PF(Product Function)分量,其中每一个 PF 分量由一个包络信号和一个纯调频信号相乘而得到,代表了一个瞬时频率具有物理意义的单分量的调幅-调频信号,能有效地反映出原始信号的真实信息,对其进行相应能量参数计算可以准确表征不同机械故障下振动信号的能量特征^[5-6]. 在利用故障特征量进行故障识别方面,常用方法有神经网络、贝叶斯分类、支持向量机、K-聚类、蚁群聚类等方法,其中支持向量机在解决小样本、高维数、非线性模式识别方面表现出明显的优势^[7-8]. 为此,将局部均值分解(Local mean decomposition,简称 LMD)的 PF 分量能量特征和支持向量机(Support Vector Machine,简称 SVM)相结合应用于变速箱滚动轴承诊断,提出一种基于 PF 能量特征和 SVM 的变速箱轴承故障诊断方法,并进行了相应的实验验证.

1 局部均值分解

LMD 方法本质上是从原始信号中分离出纯调频信号和包络信号,将纯调频信号和包络信号相乘便可以得到一个瞬时频率具有物理意义的 PF 分量,循环处理至所有的 PF 分量分离出来,便可以得到原始信号的时频分布. 对于给定的原始信号 $z(t)$ 分解成 k 个 PF 分量和 u_k 之和^[9-10]

$$z(t) = \sum_{p=1}^k PF_p(t) + u_k(t). \quad (1)$$

将所用 PF 分量的瞬时幅值和瞬时频率组合便可以得到原始信号 $z(t)$ 完整的时频分布. 图 1 为

采集的某滚动轴承内圈有故障时的振动加速度信号,对其进行 LMD 分解,如图 2,多分量的复杂的调幅-调频信号被分解为单分量的调幅-调频信号,分解后的各个 PF 分量与信号中相应的成分存在对应关系,即各个分量反映了信号中存在的不同的特征成分.




图 1 具有内圈故障的滚动轴承故障振动信号




图 2 具有内圈故障的滚动轴承振动信号的 LMD 分解

将正常、内圈点蚀和外圈压痕 3 种类型进行 LMD 分解,取分解后的前 7 层,然后计算每一层的能量作为特征向量,其结果如表 1 所示. 从表 1 可以看出,不同类型的故障经过 LMD 分解后得到 PF 分量的能量特征各不相同,说明 PF 分量能量作为特征向量可以用作支持向量机的输入向量.

表 1 正常、内圈点蚀和外圈压痕特征向量

类型	PF_1	PF_2	PF_3	PF_4	PF_5	PF_6	PF_7
正常	0.128	0.382	0.212	0.125	0.107	0.234	0.129
内圈点蚀	0.292	0.300	0.114	0.047	0.013	0.016	0.029
外圈压痕	0.083	0.126	0.086	0.033	0.007	0.056	0.065

2 支持向量机

设有 2 类线性可分的样本集合: $(x_i, y_i), i = 1, \dots, l; x_i \in \mathbf{R}^n; y \in \{+1, -1\}$, 其中, l 为样本数, n 为输入维数. 线性判别函数的一般形式为 $f(x) = \omega x + b$, 对应的分类平面方程为^[11-14]:

$$\omega x + b = 0. \quad (2)$$

式中, $\omega = [\omega_1, \omega_2, \dots, \omega_n]$ 是确定一个超平面的权重向量, b 为常数. 将判别函数进行归一化,使两类所有样本都满足 $|f(x)| \geq 1$, 此时离分类面最近的样本 $f(x) = 1$ 要求分类面对所有样本都能正确分类,即:

$$y_i [(\omega \cdot x_i) + b] - 1 \geq 0. \quad (3)$$




图3 最优分类超平面

满足式(3)且使 $\|\omega\|^2/2$ 最小的分类面就是最优分类超平面 H . 如图3中的实心点和空心点分别代表的是2类样本, H 是把2类样本分开的分类线, H_1 和 H_2 分别是各类样本中离分类线最近的样本, 而且平行于分类线; H_1, H_2 上的数据样本称为支持向量, H 使得 H_1 和 H_2 之间的距离, 也就是分类间隔 (margin) 最大, 故为最优分类线. 把最优分类线推广到多维空间, 就是最优分类面. 最优分类面问题的解可写为

$$f(x) = \text{sgn}\{(\omega \cdot x) + b\} = \text{sgn}\left\{\sum_{i=1}^l \alpha_i y_i (x \cdot x_i) + b\right\}. \quad (4)$$

$$\begin{cases} \max \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j (x_i \cdot x_j); \\ \text{s. t.} & \alpha_i \geq 0; \\ & \sum_{i=1}^l \alpha_i y_i = 0. \end{cases} \quad (5)$$

使式(5)中 α_i 不为零的样本 x_i , 即为支持向量. 阈值和权值分别为 $b = y_i - \omega \cdot x_i, \omega = \sum_{i=1}^l \alpha_i y_i x_i$.

对于非线性分类问题, 若在原始空间中的最优分类面不能得到满意的分类效果, 可通过非线性映射 $\varphi: \mathbf{R}^n \rightarrow F, x \rightarrow \varphi(x)$ 将原空间 \mathbf{R}^n 中的样本 x 映射到多维线性可分特征空间 F , 待分类的样本变为 $\{\varphi(x_1), \varphi(x_2), \dots, \varphi(x_n)\}$, 非线性映射 φ 在一般情况下难以求解, 通过引入核函数 $K(x_i, x_j)$ 可以解决这个问题. 这样, 在特征空间构造出最优分类面, 通过选择不同的核函数可以构造出不同的支持向量机的分类器. 最优分类面公式为

$$f(x) = \sum_{i=1}^n \alpha_i y_i \langle \varphi(x_i), \varphi(x) \rangle + b = \sum_{i=1}^n \alpha_i y_i K(x_i, x) + b. \quad (6)$$

3 基于PF能量特征和SVM的变速箱轴承故障诊断方法及应用

基于PF能量特征和SVM的变速箱轴承故障

诊断方法流程如图4所示, 包括如下步骤:

- 1) 实验采集正常轴承、内圈点蚀和外圈压痕3种故障状态下振动信号各 N 组;
- 2) 对每组振动信号数据样本进行LMD分解, 得到 n 个PF分量, 每个PF分量对应一个数据样本 $\{z_{pt}\} (p=1, 2, \dots, n, t=1, 2, \dots, N)$, 进行能量归一化得到新的时间序列 $\{\hat{z}_{pt}\}$, 以此去除原始采样信号的幅值对系统状态特征参数提取的影响;
- 3) 为了减少计算的复杂度, 取前 i 层分解的PF分量, 计算出每个PF分量的能量 E_i ;
- 4) 对每组振动信号数据样本可以构造一个 i 维的能量特征向量矩阵 $T = [E_1, E_2, \dots, E_i]$, 并作为特征向量输入支持向量机;
- 5) 建立支持向量机组成的故障分类器, 将能量特征向量 T 输入支持向量机, 对支持向量机进行训练. 如果要区分轴承正常、内圈点蚀、外圈压痕3种状态, 只需设计2个分类器即可. 对SVM1定义 $y = +1$ 表示内圈点蚀, $y = -1$ 表示正常或外圈压痕, 即用SVM1将正常分离出来; 再对SVM2定义 $y = +1$ 表示正常, $y = -1$ 表示外圈压痕, 即用SVM2将外圈压痕分离出来. 如果有更多类型的故障类型需要识别, 则可依次设计SVM3, SVM4等将其余故障类型识别出来.




图4 基于PF能量特征和SVM的变速箱轴承故障诊断方法

以图5所示变速箱实验系统采集的各类故障振动信号为例, 采用上述基于PF能量特征和SVM的故障诊断方法进行滚动轴承诊断. 对采集的各类




图5 变速箱实验系统

故障振动信号进行 LMD 分解,每类故障提取 50 个样本,组成 50×7 的样本集,随机提取 40 个样本作

为训练样本,剩余 10 个样本作为测试样本,部分特征量见表 2 所示.

表 2 部分特征量值

样本	PF_1	PF_2	PF_3	PF_4	PF_5	PF_6	PF_7
x_1	0.128 49	0.382 54	0.212 28	0.125 38	0.107 99	0.234 54	0.129 71
x_2	0.142 20	0.284 7	0.326 26	0.386 93	0.410 58	0.021 54	0.041 39
x_3	0.292 46	0.300 39	0.047 63	0.013 06	0.016 38	0.016 38	0.029 09
x_4	0.411 13	0.177 47	0.122 31	0.064 19	0.020 07	0.021 80	0.001 41
x_5	0.070 90	0.044 93	0.052 88	0.058 28	0.017 18	0.006 56	0.005 99
x_6	0.070 99	0.094 99	0.135 47	0.055 55	0.015 60	0.002 01	0.000 22
x_7	0.083 23	0.126 20	0.086 16	0.033 39	0.007 61	0.056 06	0.065 74
x_8	0.147 44	0.141 72	0.125 01	0.051 44	0.026 00	0.004 69	0.001 94

作为滚动轴承故障信号的识别,理想的输出结果应该可以直接进行故障信号的识别,表 3 为网络训练的期望输出样本. 分别以 10 个测试样本将其作为 SVM 分类器的输入,以 SVM 分类器的输出来识别各类故障类型,诊断结果如表 4 所示. 从表 4 可知,采用基于 PF 能量特征和 SVM 结合的诊断

方法的故障诊断率较高,正确率达到 90% 以上.

表 3 样本的期望输出

诊断轴承类型	期望输出
正常	(-1, +1, -1)
内圈点蚀	(+1, -1, -1)
外圈压痕	(-1, -1, -1)

表 4 基于 PF 能量特征和 SVM 方法的诊断结果

诊断轴承类型	输出	正确	错误	正确率/%
正常	(-1, +1, -1) (-1, +1, -1) (-1, +1, -1) (-1, +1, -1) (-1, +1, -1) (-1, +1, -1) (-1, +1, -1) (-1, +1, -1) (-1, +1, -1) (-1, +1, -1)	10	0	100
内圈点蚀	(+1, -1, -1) (-1, -1, -1) (+1, -1, -1) (+1, -1, -1) (+1, -1, -1) (+1, -1, -1) (+1, -1, -1) (+1, -1, -1) (+1, -1, -1) (+1, -1, -1)	9	1	90
外圈压痕	(-1, -1, -1) (-1, -1, -1) (-1, -1, -1) (-1, -1, -1) (-1, -1, -1) (-1, -1, -1) (-1, -1, -1) (-1, -1, -1) (-1, +1, -1) (-1, -1, -1)	9	1	90

SVM 和 BP 神经网络 2 类分类器诊断的准确率如表 5 所示,从表中可以看出,变速箱滚动轴承的正常、内圈点蚀、外圈压痕典型故障,BP 神经网络方法的诊断准确率分别为 100%、95% 和 80%, SVM 的诊断准确率分别为 100%、90% 和 90%. 在正常、内圈故障方面 SVM 和 BP 神经网络的诊断效果相同,外圈故障方面 SVM 比 BP 神经网络的诊断效果要好. 测试结果显示,SVM 以支持向量机作为分类器,测试精度比 BP 神经网络性能要好,即使是在小样本情况下,支持向量机仍具有较好的诊断效果. 通过上述测试对比分析可以得出,结合 LMD 和支持向量机的轴承诊断方法,将为变速箱滚动轴承的故障诊断提供一种实用且准确的故障诊断方法.

表 5 SVM 和 BP 方法的故障诊断测试结果对比

轴承类型	算法	测试样本数	诊断结果		诊断准确率/%
			正确	误判	
正常	SVM	10	10	0	100
	BP		10	0	100
内圈点蚀	SVM	10	9	1	90
	BP		9	1	90
外圈压痕	SVM	10	9	1	90
	BP		8	2	80
总数	SVM	30	28	2	93
	BP		27	3	90

4 结论

1) LMD 方法是一种可根据信号自身的特点,自适应地选择频带,确定信号在不同频带的分辨

率,把复杂的多分量信号分解为有限个瞬时频率具有物理意义的PF分量之和,对每一个平稳PF分量突出了原信号不同的局部特征信息,能够有效提取故障特征信息;

2)在小样本情况下,结合PF能量特征量和支持向量机的诊断方法,能有效识别滚动轴承故障类型,具有很高的变速箱滚动轴承的故障诊断正确率,降低了需要大量数据参与训练的复杂性.

参考文献:

- [1] Classen T, Mecklenbrauker W. The aliasing problem in discrete - time Wigner distribution [J]. IEEE Transactions on Acoustics, Speech, and Signal Processing, 1983, 31 (5): 1067 - 1072.
- [2] Lee J H, Kim J, Kim H J. Development of enhanced Wigner - Ville distribution function [J]. Mechanical Systems and Signal Processing, 2001, 13 (2): 367 - 398.
- [3] Mallat S. A theory for multi - resolution decomposition, the wavelet representation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1989, 11 (7): 674 - 689.
- [4] Cheng J S, Yu D J, Yang Y. Energy operator de - modulating approach based on EMD and its application in mechanical fault diagnosis [J]. Chinese Journal of Mechanical Engineering, 2004, 40(8): 115 - 118.
- [5] Smith J S. The local mean decomposition and its application to EEG perception data [J]. Journal of the Royal Society Interface, 2005, 2(5): 443 - 454.
- [6] 任达千,杨世锡,吴昭同,等. LMD 时频分析方法的端点效应在旋转机械故障诊断中的影响 [J]. 中国机械工程, 2012, 28(8): 951 - 956.
- [7] Keerthi S S, Lin C J. Asymptotic behaviors of support vector machines with Gaussian Kernel [J]. Neural Computation, 2003, 15 (7): 1667 - 1689.
- [8] Chapelle O, Vapnik V. Choosing multiple parameters for support vector machines [J]. Machine Learning, 2002, 46 (1 - 3): 131 - 159.
- [9] 李志农,刘卫兵,易小兵. 基于局部均值分解的机械故障欠定盲源分离方法研究 [J]. 机械工程学报, 2011, 47(7): 97 - 102.
- [10] 程军圣,杨宇,于德介. 局部均值分解方法及其在齿轮故障诊断中的应用 [J]. 机械工程学报, 2009, 22(1): 76 - 83.
- [11] 黄勇,郑春颖,宋忠虎. 多类支持向量机算法综述 [J]. 计算技术与自动化, 2005, 24(4): 61 - 63.
- [12] 易辉,宋晓峰,姜斌,等. 基于结点优化的决策导向无环图支持向量机及其在故障诊断中的应用 [J]. 自动化学报, 2010, 36(3): 427 - 431.
- [13] 陆波,尉询楷,毕笃彦. 支持向量机在分类中的应用 [J]. 中国图像图形学报, 2005, 10(10): 1029 - 1034.
- [14] 刘志刚,李德仁,秦前清,等. 支持向量机在多类分类问题中的推广 [J]. 计算机工程与应用, 2004(7): 10 - 13.