

基于 MCKD—EEMD 近似熵和 TWSVM 的 齿轮箱故障诊断

张 曹, 陈 珺, 刘 飞

(江南大学 轻工过程先进控制教育部重点实验室, 江苏 无锡 214122)

摘要: 在复杂环境下齿轮箱信号往往会淹没在噪声信号中, 特征向量难以提取; 为了有效地进行故障诊断, 提出了基于最大相关反褶积 (MCKD) 总体平均经验模态分解 (EEMD) 近似熵和双子支持向量机 (TWSVM) 的齿轮箱故障诊断方法; 首先采用 MCKD 方法对强噪声信号进行滤波处理, 在采用 EEMD 方法对齿轮箱信号进行分解, 分解后得到本征模函数 (IMF) 分量进行近似熵求解, 得到齿轮特征向量, 最后将其输入到 TWSVM 分类器中进行故障识别; 仿真实验表明, 采用 MCKD—EEMD 方法能够有效地提取原始信号, 与其他分类器相比, TWSVM 的计算时间短, 分类效果好等优点。

关键词: 最大相关反褶积; 总体平均经验模态分解; 近似熵; 双子支持向量机; 齿轮箱故障诊断

Gearbox Fault Diagnosis Based on MCKD—EEMD—Approximate Entropy and TWSVM

Zhang Cao, Chen Jun, Liu Fei

(Ministerial Key Laboratory of Advanced Control for Light Industry Processes,
Jiangnan University, Wuxi 214122, China)

Abstract: Gearbox signals always tend to be drowned in the noise at a complex environment, resulting problem in feature vector extraction/which make difficulty for feature vector extraction. In order to effectively diagnose gearbox fault, a method for gearbox is proposed based on maximum correlated kurtosis deconvolution (MCKD) ensemble empirical mode decomposition (EEMD) approximate entropy and twin support vector machine (TWSVM). Firstly, the noise signal is filtered by MCKD method, then EEMD method is used to decompose the signal of gearbox. To get signal eigenvectors, the intrinsic mode functions (IMF) obtained from the decomposition is used to calculate approximate entropy. Finally, signal eigenvectors are input to the TWSVM classifier for fault identification. Simulation results show that the MCKD—EEMD method can be used to extract raw signal effectively, and the TWSVM classifier performs a better classification.

Keywords: maximum correlated kurtosis deconvolution; ensemble empirical mode decomposition; approximate entropy; twin support vector machine; gearbox fault diagnosis

0 引言

现代的工业设备中, 齿轮箱占据着重要的地位, 随之而来的便是齿轮箱故障诊断问题, 这使得故障诊断技术的要求也越来越高。齿轮箱故障诊断^[1]实质上就是对信号的特征提取和模式识别, 能否有效地对信号进行特征提取和准确的分类, 直接影响到对故障诊断的准确性和预判性。由于齿轮箱在一些复杂环境下运行, 所采集的信号往往会被噪声所淹没, 特征向量难以提取, 其次对提取的特征向量分类效果还有待提高。

针对齿轮箱信号中含有复杂的噪声成分, 故障特征难以提取, 崔玲丽^[2]等人提出了针对轴承早期故障的特征提取, 提出了一种共振解调结合小波包系数熵与共振解调结合的降噪算法; 马伦^[3]等人, 提出一种利用尺度能量谱优化 Morlet 小波变换尺度, 从而实现了对轴承故障特征的有效提取; 王志坚^[4]等人提出

了基于最小熵反褶积作为前置滤波器对信号进行总体平均经验模态分解, 从而来提取滚动轴承微弱故障特征; 王宏超^[5]等人同样使用 MED 对干扰信号进行降噪处理, 并通过稀疏分解来提取故障特征提取; 任学平^[6]等人使用角域重采样算法将非平稳信号转化为平稳信号, 在用级联最大相关峭度反褶积来提取信号中的干扰成分; 任学平^[7]等人通过运用 MCKD 对含有强噪声的轴承振动信号进行降噪预处理来提取信号特征向量。

将提取好的特征向量进行故障模式识别, 其方法有很多, 例如 Verma^[8]等人采用了神经网络方法在滚动轴承上的故障诊断; 游子跃^[9]等人提出了基于 EEMD 和 BP 神经网络的风机齿轮箱故障诊断方法; 于德介^[10]人采用了 EMD 和 SVM 结合方法用于故障诊断; 黄俊^[11]等人采用了 LSSVM 方法用于齿轮箱故障诊断; 赵琨^[12]等人利用 TWSVM 基于商业银行的信用卡数据, 建立了信用卡流失分析模型; 本文采用的是双子支持向量机的方法, 双子支持向量机^[13] (twin support vector machines 简称 TWSVM) 是由 Jayadeva 等人提出的一种基于 SVM 的一种改进算法, 它是通过求解两个二次优化问题来代替 SVM 的一个优化问题, 从而获得两条非平行的超平面, 与传统的 SVM、LSSVM 相比, TWSVM 的计算时间更短, 分类效果更好^[14-15]。

本文是通过将信号进行降噪、提取、分类结合的方法对故障进行诊断。首先采用 MCKD^[16]对齿轮信号进行降噪处理,

收稿日期: 2017-02-22; 修回日期: 2017-03-14。

基金项目: 国家自然科学基金资助(61403167)。

作者简介: 张 曹(1990-), 男, 安徽合肥人, 硕士研究生, 主要从事齿轮箱故障诊断应用方向的研究。

陈 珺(1980-), 女, 江苏无锡人, 副教授, 硕士研究生导师, 主要从事模糊控制的诊断与研究。

刘 飞(1965-), 男, 安徽人, 教授, 博士生导师, 主要从事先进控制理论与应用、过程监控等方向的研究。

得到齿轮箱原始信号，在对原始信号进行 EEMD^[17] 分解，得到 IMF 分量，再进行近似熵计算作为特征向量，最后建立 TWSVM 分类器进行快速、精确地分类，从而有效的进行故障诊断^[18-19]。

1 MCKD 算法

设采用传感器提取的齿轮箱故障信号为：

$$y(n) = h(n) * x(n) + e(n) \quad (1)$$

式中， $y(n)$ 为传感器采集到的故障信号； $x(n)$ 为故障周期性冲击成分； $h(n)$ 为系统传输路径的响应； $e(n)$ 为噪声成分。

MCKD 算法的目的就是寻找一个冲击响应滤波器 $w(l)$ ，通过使得采集的故障信号 $y(n)$ 尽可能的恢复到原始信号 $x(n)$ ，并使其峭度达到最大，即：

$$x(n) = y(n) * w(l) \quad (2)$$

MCKD 的峭度到达最大时，表明信号中的冲击成分显著，即迭代终止。因此，该算法很好的对信号进行降噪，并凸现了信号尖端脉冲成分。

相关峭度定义为：

$$CK_M(t) = \frac{\sum_{n=1}^N \left(\prod_{m=0}^M y(n-mT) \right)^2}{\left(\sum_{n=1}^N y^2(n) \right)^{M+1}} \quad (3)$$

式中， M 为位移数； T 为冲击信号周期。

MCKD 算法优化的目标函数为：

$$MCKD_M(T) = \max_{w(l)} \frac{\sum_{n=1}^N \left(\prod_{m=0}^M y(n-mT) \right)^2}{\left(\sum_{n=1}^N y^2(n) \right)^{M+1}} \quad (4)$$

式中， $l = 1, 2, 3, \dots, L$ 。

求解上述优化问题可令：

$$\frac{d}{dw(l)} CK_M(T) = 0 \quad (5)$$

得到的滤波器结果可用矩阵形式来表述为：

$$w = \frac{\| \| y^2 \| \|}{2} (X_0 X_0^T)^{-1} \sum_{n=0}^M X_{nT} A_n \quad (6)$$

通过以上分析 MCKD 算法流程归结如下：

- 1) 合理选取周期 T 、滤波器长度 L 和移位数 M ；
- 2) 计算原信号 $x(n)$ 的 $X_0 X_0^T$ 和 X_{mT} ；
- 3) 求取滤波后的信号 $y(n)$ ；
- 4) 根据 $y(n)$ 计算 A_m 和 B ；
- 5) 更新滤波器系数 $w(l)$ ；
- 6) 若滤波前后信号的 $\Delta CK_M(T) < \epsilon$ ，需停止迭代，否则跳回第 3 步。 ϵ 为给定的阈值用来控制循环的次数。

2 EEMD 算法

EEMD 算法是一种添加白噪声分析方法，通过对信号中加入白噪声，可以消除 EMD 的模式混叠现象。其具体算法如下：

1) 确定信号 $x(t)$ 并在其信号中加入均值为 0、幅值标准差为常数的白噪声 $n_i(t)$ ，即：

$$x_i(t) = x(t) + n_i(t) \quad (7)$$

式中， $i = 1, 2, 3, \dots, N$ ；

2) 采用 EMD 方法对信号 $x_i(t)$ 进行分解，得到 IMF 分量 $c_{ij}(t)$ ，其是经过加入 i 次高斯白噪声后，经过 EMD 分解得到的第 j 个 IMF 分量。

3) 若 $i < N$ 则 $i = i + 1$ 重复步骤 2；

4) 将所有经过 EMD 分解得到的 IMF 分量进行总体平均运算，最终得到 EEMD 分解后的 IMF 为：

$$c_j(t) = \frac{1}{N} \sum_{i=1}^N c_{ij} \quad (8)$$

其中： c_j 表示为 EEMD 分解得到的第 j 个分量。

3 近似熵原理

近似熵是用来描述信号的非规则性和复杂性，近似熵增大表明信号的复杂程度增大。下面给出具体的算法步骤。

设采集到的原始数据为 $\{u(i), i = 1, 2, \dots, N\}$ ，预先给定模式维数 m 和相似容限 r 的值，则近似熵可以通过以下步骤计算得到：

1) 将序列 $\{u(i)\}$ 按顺序组成 m 维矢量 $X(i)$ ，即：

$$X(i) = [u(i), u(i+1), \dots, u(i+m-1)] \quad (9)$$

式中， $i = 1 \sim N - m + 1$ 。

2) 对每一个 i 值计算矢量 $X(i)$ 与其余矢量 $X(j)$ 之间的距离：

$$d[X(i), X(j)] = \max_{k=0 \sim m-1} |u(i+k) - u(j+k)| \quad (10)$$

3) 给定阈值 $r(r > 0)$ ，对每一个 i 值统计 $d[X(i), X(j)] < r$ 的数目及此数目与总的矢量个数 $N - m + 1$ 的比值，记作 $C_i^m(r)$ ，即：

$$C_i^m(r) = \frac{y}{N - m + 1} \quad (11)$$

其中： y 为 $d[X(i), X(j)] < r$ 的数目。

4) 计算 $C_i^m(r)$ 的对数，并对所有 i 进行平均值，记做 $\Phi^m(r)$ ，即：

$$\Phi^m(r) = \frac{1}{N - m + 1} \sum_{i=1}^{N-m+1} \ln C_i^m(r) \quad (12)$$

5) 再将维数加 1，变成 $m + 1$ 维，重复步骤 1) ~ 4)，得到 $\Phi^{m+1}(r)$ 。

6) 这样理论上这个序列的近似熵为：

$$ApEn(m, r, N) = \lim_{N \rightarrow \infty} [\Phi^m(r) - \Phi^{m+1}(r)] \quad (13)$$

然而实际计算时， N 为有限值，那么近似熵估计值可以表示为：

$$ApEn(m, r, N) = \Phi^m(r) - \Phi^{m+1}(r) \quad (14)$$

通常 $m = 2, r = 0.1 \sim 0.25SD(u)$ ， SD 表示标准差，所得到的近似熵统计特性较为合理。

4 双子支持向量机原理

双子支持向量机 (TWSVM) 是 Jayadeva 等人在广义特征支持向量机 (GEPSSVM^[20]) 的基础上提出的。TWSVM 与 GEPSSVM 分类思想基本相似，目的都是在两个非平行超平面中使一类样本点尽可能靠近一条超平面，而尽可能远离另外一条超平面。TWSVM 可分为线性和非线性，下面为线性 TWSVM 的分类原理。

给定训练集

$$T = \{(x_1, y_1), \dots, (x_n, y_n)\} \in (R^n \times Y)^l \quad (15)$$

其中： $x_i \in R^n, Y = \{-1, +1\}, i = 1, \dots, l$ 。我们将属于 $+1$ 类的样本点记作 A ，类似的，将 -1 类的样本点记作 B ，双子支持向量机是寻求一对分类超平面：

$$f_1(x) = w_1^T x + b_1 \quad f_2(x) = w_2^T x + b_2 \quad (16)$$

其中： $w \in R^n, b \in R$ 。

通过求解如下两个二次规划问题:

$$\begin{aligned} & \min_{w_1, b_1, \xi} (Aw_1 + e_1 b_1) + c_1 e_2^T \xi \\ & s. t. -(Bw_1 + e_2 b_1) + \xi \geq e_2, \xi \geq 0 \end{aligned} \quad (17)$$

和

$$\begin{aligned} & \min_{w_2, b_2, \xi} (Aw_2 + e_2 b_2) + c_2 e_1^T \xi \\ & s. t. -(Bw_2 + e_1 b_2) + \xi \geq e_1, \xi \geq 0 \end{aligned} \quad (18)$$

其中: c_1, c_2 是惩罚参数, e_1, e_2 是适当维数的单位向量, ξ 为松弛变量。

对于上面两个优化问题, 通过引入 Lagrangian 函数:

$$\begin{aligned} L(w_1, b_1, \xi, \alpha, \beta) &= \frac{1}{2} (Aw_1 + e_1 b_1)^T (Aw_1 + e_1 b_1) + \\ & c_1 e_2^T \xi - \alpha^T (- (Bw_1 + e_2 b_1) + \xi - e_2) - \beta^T \xi \end{aligned} \quad (19)$$

此处 α, β 是拉格朗日乘子。并通过 Karush—Kuhn—Tucker (KKT) 条件得到如下对偶形式:

$$\begin{aligned} & \max_{\alpha} e_2^T \alpha - \frac{1}{2} a^T G (H^T H)^{-1} G^T \alpha \\ & s. t. 0 \leq \alpha \leq c_1 \end{aligned} \quad (20)$$

类似的, 另一个对偶形式为:

$$\begin{aligned} & \max_{\beta} e_1^T \beta - \frac{1}{2} \beta^T P (Q^T Q)^{-1} P^T \beta \\ & s. t. 0 \leq \beta \leq c_2 \end{aligned} \quad (21)$$

其中: $G = [B, e_2], H = [A, e_1], P = [A, e_1], Q = [B, e_2]$ 。

通过求解上述两个对偶问题可得:

$$\begin{aligned} [w_1, b_1]^T &= - (H^T H)^{-1} G^T \alpha \\ [w_2, b_2]^T &= - (Q^T Q)^{-1} P^T \beta \end{aligned} \quad (22)$$

因此, 对于一个新的点, 可判别其类型为:

$$Class = \arg \min_{k=1,2} \frac{|\tau_k^T + b_k|}{\|\tau_k\|_2} \quad (23)$$

其中: $|\cdot|$ 为绝对值, $\|\cdot\|_2$ 为二范数。

5 故障识别方法

基于 MCKD—EEMD 近似熵和 TWSVM 的齿轮箱故障诊断方法框图如图 1 所示。




图 1 齿轮箱故障诊断流程图

故障诊断的具体步骤如下:

- 1) 分别采集齿轮箱正常、断齿和点蚀的三种状态下的信号, 并将采集得到的信号作为样本数据和测试数据。
- 2) 将采集得到的信号进行 MCKD 消噪, 在通过包络谱的方法对消噪前后的效果进行对比。
- 3) 对齿轮箱信号进行 EEMD 分解, 并分别计算前 n 个 IMF 分量的近似熵。
- 4) 计算得到的近似熵后组建特征矩阵, 将组建好的特征矩阵输入到 TWSVM 分类器中进行故障诊断。

6 仿真与实验

实验数据是在 QPZZ—II 旋转机械振动分析及故障诊断实验平台完成的, 分别获得了齿轮正常、断齿和点蚀故障下的实验数据, 实验平台如图 2 所示。

实验中, 仅取齿轮箱断齿信号的时域图和 MCKD 去噪后




图 2 故障诊断实验平台

的时域图为例, 对他们进行包络谱分析。其中, 采样频率 $2\ 000 \times 2.56$ Hz, 齿轮转频为 24.5 Hz。




图 3 齿轮断齿时域波形图




图 4 齿轮断齿 MCKD 去噪后的时域波形图




图 5 断齿信号包络谱图

从上图可以看出, 消噪后的包络谱中可以很清楚的看出齿轮箱信号转频以及多倍频, 而没有消噪的信号则找不出转频和其多倍频, 因此在没有消噪的情况下信号的特征向量是难以准确的提取。

通过实验平台分别对三种不同状态的齿轮箱信号进行采集, 在分别用 MCKD 消噪后得到各 120 组数据, 分别取前 90 组作为训练样本, 剩余的作为测试样本。为了减少篇幅, 这里我们仅对断齿信号的一组进行 EEMD 分解, 结果如图 6 所示。

从图 6 的 EEMD 分解结果中可以看出, 不同尺度且不规则的 IMF 分量主要体现在前几个分量当中, 考虑到文章篇幅, 仅选择分解后的前 4 个序列和列出每种状态下的 5 个近似熵值的特征向量。如表 1 所示。




图 6 断齿故障信号的 EMD 分解图

表 1 不同故障类型的近似熵

齿轮状态	信号序列	EEMD 特征向量			
		IMF1	IMF2	IMF3	IMF4
正常	1	1.2278	0.9263	0.7721	0.6454
	2	1.2497	0.9406	0.7453	0.6423
	3	1.3461	1.0482	0.7939	0.6408
	4	1.3371	0.9149	0.7086	0.6328
	5	1.2626	0.7988	0.6890	0.5869
断齿	1	1.6767	1.4829	1.0174	0.6720
	2	1.6512	1.5245	0.9083	0.6777
	3	1.7044	1.4650	0.9754	0.6587
	4	1.6992	1.4692	0.9301	0.6626
	5	1.6603	1.4822	0.9511	0.7030
点蚀	1	1.3190	1.1033	0.7482	0.6426
	2	1.3048	1.0175	0.8173	0.6780
	3	1.3380	1.0615	0.7841	0.6504
	4	1.2364	1.0745	0.7404	0.6620
	5	1.3013	1.0251	0.7919	0.6557

为了比较消噪前后 TWSVM 的识别率，将每组剩余 30 组数据作为测试样本，分别通过 SVM、TWSVM、MCKD-SVM 和 MCKD-TWSVM 进行训练，测试结果如表 2 所示。

表 2 消噪前后 SVM 与 TWSVM 性能比较

网络种类	训练样本	测试样本	训练时间/s	识别率/%
SVM	270	90	4.83	82.22
TWSVM	270	90	1.05	96.67
MCKD-SVM	270	90	4.35	88.89
MCKD-TWSVM	270	90	0.98	97.78

从表 2 可见，TWSVM 比 SVM 和 LSSVM 识别精度更高且训练时间更短，而经过 MCKD 消噪后的比没有消噪的识别精度高，所以 MCKD-TWSVM 具有更好的预测效果。同时，本实验中，样本量较少，说明 TWSVM 适合小样本量的分类。

6 结论

通过基于 MCKD-EEMD 近似熵和双子支持向量机的齿轮箱故障诊断方法，可得如下结论：

1) MCKD-EEMD 与近似熵相结合，能够有效地把复杂信号中的噪声去除，从而利用 EEMD 分解得到的 IMF 分量，通过近似熵的方法得到不规则的且有效的故障特征，从而成为故障分类先决条件。

2) 通过消噪后和没有消噪的对比可以看出，MCKD-TWSVM 方法时间复杂度更小，且测试精度更高，从而能够更准确地进行故障诊断。

参考文献：

[1] 魏秀业, 潘宏侠. 齿轮箱故障诊断技术现状及展望 [J]. 测试技术学报, 2006, 20 (4): 368-376.

[2] 崔玲丽, 康晨晖, 胥永刚, 等. 滚动轴承早期冲击性故障特征提取的综合算法研究 [J]. 仪器仪表学报, 2010 (11): 2422-2427.

[3] 马伦, 康建设, 孟妍, 等. 基于 Morlet 小波变换的滚动轴承早期故障特征提取研究 [J]. 仪器仪表学报, 2013, 34 (4): 920-926.

[4] 王志坚, 韩振南, 刘邱超, 等. 基于 MED-EEMD 的滚动轴承微弱故障特征提取 [J]. 农业工程学报, 2014, 30 (23): 70-78.

[5] 王宏超, 陈进, 董广明. 基于最小熵解卷积与稀疏分解的滚动轴承微弱故障特征提取 [J]. 机械工程学报, 2013, 49 (1): 88-94.

[6] 任学平, 张玉皓, 邢义通, 等. 基于角域级联最大相关峭度反褶积的滚动轴承早期故障诊断 [J]. 仪器仪表学报, 2015, 36 (9): 2104-2111.

[7] 任学平, 王朝阁, 张玉皓. 基于 MCKD-EEMD 的滚动轴承微故障特征提取 [J]. 机械设计与制造, 2016 (8): 193-196.

[8] Sreejith B, Verma A K, Srividya A. Fault diagnosis of rolling element bearing using time-domain features and neural networks [A]. 2008 IEEE Region 10 and the Third international Conference on Industrial and Information Systems [C]. IEEE, 2008: 1-6.

[9] 游子跃, 王宁, 李明明, 等. 基于 EEMD 和 BP 神经网络的风机齿轮箱故障诊断方法 [J]. 东北电力大学学报, 2015, 35 (1): 64-72.

[10] 于德介, 杨宇, 程军圣. 一种基于 SVM 和 EMD 的齿轮故障诊断方法 [J]. 机械工程学报, 2005, 41 (1): 140-144.

[11] 黄俊, 潘宏侠, 都衡. 基于 EMD 近似熵和 LSSVM 的齿轮箱故障诊断研究 [J]. 组合机床与自动化加工技术, 2014 (3): 111-113.

[12] 赵琨, 许洪贵, 田英杰. 基于双子支持向量机的信用卡流失分析 [J]. 数学的实践与认识, 2015 (17): 85-92.

[13] Khemchandani R, Chandra S. Twin support vector machines for pattern classification [J]. IEEE Transactions on pattern analysis and machine intelligence, 2007, 29 (5): 905-910.

[14] Kumar M A, Gopal M. Application of smoothing technique on twin support vector machines [J]. Pattern Recognition Letters, 2008, 29 (13): 1842-1848.

[15] 白兰. 双子支持向量机算法研究与拓展 [D]. 吉林大学, 2014.

[16] McDonald G L, Zhao Q, Zuo M J. Maximum correlated Kurtosis deconvolution and application on gear tooth chip fault detection [J]. Mechanical Systems and Signal Processing, 2012, 33: 237-255.

[16] Guo X, Ma X. Fault diagnosis approach based on approximate entropy feature extraction with EMD and support vector machines [A]. Control Conference [C]. IEEE, 2011: 4275-4279.

[17] Wu Z, Huang N E. Ensemble empirical mode decomposition: a noise-assisted data analysis method [J]. Advances in adaptive data analysis, 2009, 1 (01): 1-41.

[18] 赵晶晶, 杨燕, 李天瑞, 等. 基于近似熵及 EMD 的高铁故障诊断 [J]. 计算机科学, 2014, 41 (1): 91-94.

[19] Zhu Z, Sun Y. Fault classification for power transmission line using EMD-approximate entropy and SVM [J]. Electric Power Automation Equipment, 2008, 7: 023.

[20] Mangasarian O L, Wild E W. Multisurface proximal support vector machine classification via generalized eigenvalues [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2006, 28 (1): 69-74.