

基于小波包变换与样本熵的滚动轴承故障诊断*

赵志宏^{1,2}, 杨绍普³

(1. 石家庄铁道大学信息科学与技术学院 石家庄, 050043)

(2. 北京交通大学机械与电子控制工程学院 北京, 100044)

(3. 石家庄铁道大学校办 石家庄, 050043)

摘要 针对滚动轴承振动信号的不规则性和复杂性可以反映轴承故障的发生和发展,提出一种基于小波包变换与样本熵的轴承故障诊断方法。样本熵可以较少地依赖时间序列的长度,将轴承振动信号进行3层小波包分解,利用分解得到的各个频带的样本熵值作为特征向量,利用支持向量机对轴承故障进行分类。对轴承内圈故障、滚动体故障和外圈故障3种故障及不同损伤程度的实测数据进行实验,结果表明该方法取得较高的识别率,具有一定的工程应用价值。

关键词 小波包变换; 样本熵; 故障诊断; 支持向量机

中图分类号 TH165.3

引言

有滚动轴承的旋转机械中,约有30%机械故障都是由滚动轴承引起的^[1],因此滚动轴承故障诊断一直是研究的热点问题^[2-4]。当轴承存在故障时,表现出非线性、非平稳特征。对于非平稳信号,传统的时域和频域方法仅在时域或频域内进行,存在一定的局限性。时频分析方法是在时、频域内对信号进行分析处理,能更好地反映信号的本质特征。小波变换是一种信号的时间尺度分析方法,具有多分辨率的特点,且在时、频域都具有表征信号局部特征的能力。小波包变换是基于小波变换的进一步发展,能够提供比小波变换更高的分辨率。小波包分解与小波分解相比,是一种更精细的分解方法,它不仅对信号的低频部分进行分解,还对信号的高频部分进行分解。当故障发生时,信号的不规则性和复杂性可以反映故障的发生和发展。度量信号复杂性的方法有Lempel-Zi复杂度^[5]、近似熵^[6]和样本熵^[7]等。Yan等^[8]将近似熵(appropriate entropy,简称ApEn)用于轴承状态监测取得了较好的效果。样本熵(sample Entropy,简称SampEn)为近似熵的改进算法,它的优越性在于可以较少地依赖时间序列长度,广泛用于生理信号处理^[9-10]。

笔者提出一种基于小波包变换与样本熵的轴承

故障诊断方法。首先,将轴承振动信号进行小波包分解;然后,计算各频段的样本熵的值,利用各频段样本熵的值作为特征向量,通过分析多个频段样本熵值的变化来判断轴承工作状态,提高轴承振动信号分析的准确性;最后,使用支持向量机作为分类器进行训练与识别。通过内圈故障、滚动体故障和外圈故障及不同损伤程度的实测信号,实验表明了该方法的有效性。

1 小波包变换

小波包变换定义两个函数^[11]

$$W_0(t) = \varphi(t) \quad (1)$$

$$W_1(t) = \psi(t) \quad (2)$$

其中: $\varphi(t)$ 与 $\psi(t)$ 分别为尺度函数与小波函数。

在正交的情况下,函数 $W_m(t)$ ($m=0,1,2,\dots$)分别为

$$W_{2m}(t) = 2 \sum_{n=0}^{2N-1} h(n)W_m(2t-n) \quad (3)$$

$$W_{2m+1}(t) = 2 \sum_{n=0}^{2N-1} g(n)W_m(2t-n) \quad (4)$$

$$W_{j,m,n}(t) = 2^{-j/2}W_m(2^{-j}t-n) \quad (5)$$

其中: j 为尺度参数;函数 $W_{j,m,n}$ 为小波包原子。

信号的小波包变换同时对信号的高频部分与低频部分进行分解。小波包分解结构如图1所示。图

* 国家自然科学基金资助项目(编号:11172182);教育部科学技术研究重点资助项目(编号:210023)

收稿日期:2010-11-05;修改稿收到日期:2011-01-10

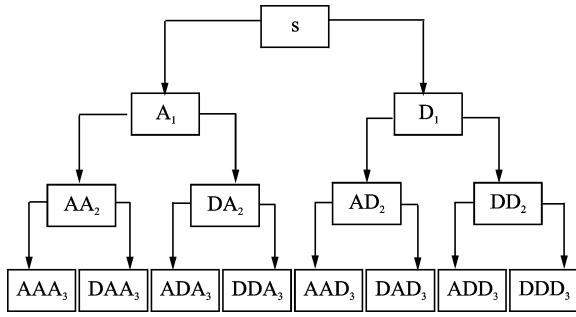


图1 3层小波包分解树结构

中:A表示低频;D表示高频;序号数为小波分解的层数(即尺度数)。可见,分解层数越大,即选择的小波包尺度越大,小波包系数对应的空间分辨率就越低。

2 样本熵概念

一般地,对于由 N 个数据组成的时间序列 $\{x(n)\}=x(1),x(2),\dots,x(N)$,样本熵的计算方法^[12]如下:

1) 按序号组成一组维数为 m 的向量序列, $X_m(1),\dots,X_m(N-m+1)$,其中 $X_m(i)=\{x(i),x(i+1),\dots,x(i+m-1)\}$, $1\leq i\leq N-m+1$ 。这些向量代表从第 i 点开始的 m 个连续的 x 的值。

2) 定义向量 $X_m(i)$ 与 $X_m(j)$ 之间的距离 $d[X_m(i),X_m(j)]$ 为两者对应元素中最大差值的绝对值

$$d[X_m(i),X_m(j)]=\max_{k=0,\dots,m-1}(|x(i+k)-x(j+k)|) \quad (6)$$

3) 对于给定的 $X_m(i)$,统计 $X_m(i)$ 与 $X_m(j)$ 之间距离小于等于 r 的 j ($1\leq j\leq N-m, j\neq i$)的数目,并记作 B_i 。对于 $1\leq i\leq N-m$,定义

$$B_i^m(r)=\frac{1}{N-m-1}B_i \quad (7)$$

4) 定义 $B^{(m)}(r)$ 为

$$B^{(m)}(r)=\frac{1}{N-m}\sum_{i=1}^{N-m}B_i^m(r) \quad (8)$$

5) 增加维数到 $m+1$,计算 $X_{m+1}(i)$ 与 $X_{m+1}(j)$ ($1\leq j\leq N-m, j\neq i$)距离小于等于 r 的个数,记为 A_i 。 $A_i^m(r)$ 定义为

$$A_i^m(r)=\frac{1}{N-m-1}A_i \quad (9)$$

6) 定义 $A^m(r)$ 为

$$A^m(r)=\frac{1}{N-m}\sum_{i=1}^{N-m}A_i^m(r) \quad (10)$$

这样, $B^m(r)$ 为两个序列在相似容限 r 下匹配 m

个点的概率,而 $A^m(r)$ 为两个序列匹配 $m+1$ 个点的概率。样本熵定义为

$$\text{SampEn}(m,r)=\lim_{N\rightarrow\infty}\left\{-\ln\left[\frac{A^m(r)}{B^m(r)}\right]\right\} \quad (11)$$

可以看到,样本熵SampEn的值与 m,r 的取值有关。因此,确定 m,r 两个参数的值对于SampEn的计算非常重要。根据文献[10]的研究结果, $m=1$ 或 $2,r=0.1\text{Std}\sim 0.25\text{Std}$ (Std为原始数据 $x(i)$ 的标准差, $i=1,2,\dots,N$)计算得到的样本熵具有较为合理的统计特性。在本研究中取 $m=2,r=0.2\text{Std}$ 。

3 基于小波包变换与样本熵的特征提取

基于小波包变换与样本熵的轴承故障诊断方法主要是通过计算小波包变换后各频带信号的样本熵值来进行故障识别。特征提取具体算法如下:

1) 对采集得到的原始轴承振动信号进行3层小波包分解,得到第3层从低频到高频8个频带系数。

2) 对小波包分解系数重构,计算各频带信号的样本熵值。

3) 构造特征向量。以各频带信号的样本熵值为元素,构造特征向量 $V=[\text{SamEn}_1,\text{SamEn}_2,\text{SamEn}_3,\text{SamEn}_4,\text{SamEn}_5,\text{SamEn}_6,\text{SamEn}_7,\text{SamEn}_8]$ 。

4 实验与结果

4.1 实验数据

实验用的实测轴承振动加速度数据来自文献[13]。滚动轴承的型号为SKF6205,轴承状态包括正常、内圈故障、滚动体故障和外圈故障4种类型,轴承的损伤状况为单一损伤,由电火花机分别在轴承内圈、滚动体和外圈人工制作,损伤直径分别为0.177 8,0.355 6,0.533 4和0.711 2 mm。电机的负载由风机调节,产生的载荷为0~2 206.496 W。将振动加速度传感器垂直固定在感应电机输出轴支撑轴承上方的壳上进行数据采集,采样速率为12 k。数据集的选择采用文献[14-15]的方法,数据集包含320个样本,每个样本的采样点数为4 096。随机选择其中100个样本作为训练数据集,其余220个样本作为测试数据集。其中,测试样本数目均为训练样本数目的两倍,这是考虑到工程应用中故障样本一般难以得到。数据集描述如表1所示。

表1 轴承数据集描述

轴承状况	损伤大小/ mm	训练 样本数	测试 样本数	分类 标签
正常	0	10	49	1
外圈 故障	0.177 8	10	19	2
	0.355 6	10	19	3
滚动体 故障	0.533 4	10	19	4
	0.177 8	10	19	4
内圈 故障	0.711 2	10	19	5
	0.177 8	10	19	7
正常	0.355 6	10	19	8
	0.533 4	10	19	9
故障	0.711 2	10	19	10

4种轴承状态的原始信号时域波形如图2所示,其中,内圈故障、滚动体故障和外圈故障的损伤程度为0.1778 mm。可以看出,从时域波形中不易分辨轴承的工作状况。




图2 4种轴承状态的原始信号时域波形

4.2 轴承信号的小波包分解

对轴承振动信号进行3层小波包分解,小波基选择采用文献[11]的方法使用DB12小波,经过3层小波包分解后各个结点代表的频率范围为 $[0 \sim 0.75 \text{ kHz}]$, $[0.75 \sim 1.5 \text{ kHz}]$, $[1.5 \sim 2.25 \text{ kHz}]$, $[2.25 \sim 3 \text{ kHz}]$, $[3 \sim 3.75 \text{ kHz}]$, $[3.75 \sim 4.5 \text{ kHz}]$, $[4.5 \sim 5.25 \text{ kHz}]$, $[5.25 \sim 6 \text{ kHz}]$ 8个频带。对小波包分解系数进行重构,得到各个频带的重构信号。轴承内圈故障信号小波包分解后得到的各结点重构信号如图3所示。

4.3 轴承不同状态小波包分解样本熵值比较

利用经过小波包分解得到的第3层各频带信号的样本熵值作为特征,得到8维的列向量。轴承正常




图3 轴承内圈故障小波包分解结果

状态、内圈故障、滚动体故障、外圈故障及不同损伤程度的训练样本集的样本熵均值与标准差如表2所示。可以看到,10种工况的轴承振动信号经小波包分解后各频带样本熵的标准差都较小,说明样本熵值比较稳定。另外,轴承在不同状态下各频段的样本熵值不相同,说明样本熵可以作为轴承故障诊断的特征。图4为10种工况轴承训练样本集在频带1与频带3样本熵值的分布情况,可以看出,10种工况轴承表现出了很好的聚类特征。

4.4 基于支持向量机的轴承故障诊断

由于支持向量机(support vector machine,简称SVM)具有泛化能力强和维数不敏感等优点,适于求解高维、小样本、非线性情况下的模式分类和回归分析等问题,因此这里选择SVM作为轴承故障诊断的分类器。SVM算法最初是为两类分类问题设计的,但轴承故障诊断属于多类模式问题,所以必须扩展(两类)支持向量机来处理多类问题。文献[16]认为“一对一”分类方法在实际应用中优于其他方法。本研究选用“一对一”的SVM多类识别方法。

实验中SVM核函数选择最常用的径向基核函数,其表达式为

$$K(x, y) = \exp\left(-\frac{\|x - y\|^2}{2\sigma^2}\right) \quad (12)$$

其中: σ 为控制核函数宽度的参数。

对于线性不可分情况,引入惩罚因子 C 来控制错误分类。图5是以 SampEn_1 与 SampEn_3 作为特征向量得到的SVM分类效果图。图中以圆圈包围的点为支持向量,中间的分类线表示最优分类面,可以看到能够对轴承进行较好地分类。应用小波包分解后各频段的样本熵值作为特征组成一个8维的特征向量,对表1所示的数据集进行分类实验,对SVM取不同的参数,识别结果如表3所示。可以看到, σ 参数对识别率的影响较大,参数 C 的取值对识别率影响

表2 训练数据集不同工况样本熵值比较

轴承状况	损伤大小/mm		SampEn ₁	SampEn ₂	SampEn ₃	SampEn ₄	SampEn ₅	SampEn ₆	SampEn ₇	SampEn ₈
正常	0	均值	0.568 1	1.588 8	2.137 1	2.095 4	1.014 5	1.558 8	1.884 3	2.078 7
		方差	0.034 4	0.012 5	0.015 0	0.017 0	0.055 6	0.027 1	0.030 4	0.011 9
内圈故障	0.1778	均值	1.046 1	1.482 0	1.650 1	1.814 6	0.930 1	1.468 5	1.757 9	1.862 4
		方差	0.025 0	0.023 6	0.032 0	0.018 2	0.032 0	0.038 7	0.021 4	0.017 6
	0.355 6	均值	0.898 6	1.528 3	1.060 5	1.690 3	0.658 5	1.258 3	1.394 4	1.476 2
		方差	0.044 6	0.045 6	0.066 1	0.095 7	0.078 8	0.165 2	0.092 7	0.100 4
	0.533 4	均值	0.920 1	1.511 9	1.200 2	1.712 0	0.609 6	1.148 7	1.187 0	1.609 7
		方差	0.015 7	0.021 5	0.051 6	0.022 2	0.050 0	0.050 2	0.036 5	0.041 1
	0.711 2	均值	1.135 9	1.492 8	1.812 7	1.893 5	0.901 5	1.535 0	1.669 8	2.004 7
		方差	0.026 9	0.037 1	0.036 0	0.018 5	0.134 7	0.084 5	0.035 0	0.034 5
滚动体故障	0.1778	均值	0.962 0	1.647 4	1.816 6	1.931 5	0.991 5	1.575 1	1.900 1	1.974 8
		方差	0.019 7	0.021 6	0.023 9	0.025 8	0.079 8	0.051 3	0.035 0	0.030 1
	0.7112	均值	0.810 0	1.384 4	1.532 2	1.745 5	0.851 8	1.397 5	1.523 2	1.822 3
		方差	0.102 2	0.050 0	0.121 5	0.051 4	0.079 1	0.065 6	0.044 9	0.041 7
外圈故障	0.177 8	均值	1.016 9	1.479 4	1.072 7	1.601 2	0.729 6	0.948 9	1.067 0	1.332 0
		方差	0.043 5	0.063 0	0.054 7	0.100 1	0.059 3	0.070 8	0.024 8	0.062 9
	0.355 6	均值	0.965 6	1.589 1	1.939 7	1.915 3	1.037 5	1.339 7	2.037 2	2.020 7
		方差	0.034 2	0.032 2	0.027 2	0.016 2	0.044 0	0.038 5	0.029 2	0.023 2
	0.533 4	均值	0.740 1	1.198 3	0.652 2	1.371 6	0.342 9	0.731 1	0.639 4	1.150 6
		方差	0.026 2	0.053 3	0.053 8	0.069 8	0.101 7	0.186 9	0.061 0	0.167 1

表3 不同参数取值下轴承故障识别率

轴承状况	正常	内圈				滚动体			外圈		%
		0	0.177 8	0.355 6	0.533 4	0.711 2	0.177 8	0.711 2	0.177 8	0.355 6	
C=10	$\sigma=0.1$	93.88	100	15.79	0	73.68	15.79	15.79	5.26	0	31.58
	$\sigma=0.2$	100	52.63	63.16	47.37	84.21	100	63.16	31.58	5.26	78.95
	$\sigma=0.5$	100	100	100	100	100	100	100	78.95	89.47	100
	$\sigma=1$	100	100	100	100	100	100	100	78.95	94.74	100
C=100	$\sigma=0.1$	93.88	100	15.79	0	73.68	26.32	15.79	5.26	0	31.58
	$\sigma=0.2$	100	52.63	63.16	47.37	84.21	100	63.16	31.58	5.26	78.95
	$\sigma=0.5$	100	100	100	100	100	100	100	78.95	89.47	100
	$\sigma=1$	100	100	100	100	100	100	100	84.21	94.74	100
C=1 000	$\sigma=0.1$	93.88	100	15.79	0	73.68	15.79	15.79	5.26	0	100
	$\sigma=0.2$	100	52.63	63.16	47.37	84.21	100	63.16	31.58	5.26	78.95
	$\sigma=0.5$	100	100	100	100	100	100	100	78.95	89.47	100
	$\sigma=1$	100	100	100	100	100	100	100	84.21	94.74	100




图4 轴承分布情况




图5 SVM 分类效果图


较小。 C 取100, σ 取1时,识别效果最好,220个测试样本中4个样本识别错误,总的识别率为98.18%,识别效果好于文献[15]提出的方法(识别率为93%)。这说明此方法可以用来进行轴承故障诊断,同时也具有对损伤程度进行识别的能力。

5 结束语

提出一种基于小波包变换与样本熵的轴承故障诊断方法。将轴承信号进行3层小波包分解,提取各频带的样本熵值作为特征,利用支持向量机进行分类。对轴承内圈故障、滚动体故障、外圈故障不同损伤程度下共10种情况进行分类实验。结果表明,轴承在出现故障情况下样本熵的值会发生改变,且不同故障样本熵值不同,表明样本熵可以作为轴承故障诊断的特征。利用SVM对220个样本进行测试,只有4个样本分类错误,表明此方法可以用于滚动轴承故障诊断。

参 考 文 献

- [1] 徐振辉,马立元.滚动轴承的故障特征提取[J].兵工自动化,2004,23(1):46-48.
Xu Zhenhui, Ma Liyuan. Picking up fault character of rolling bearings[J]. Ordnance Industry Automation, 2004,23(1):46-48. (in Chinese)
- [2] 唐贵基,蔡伟.应用小波包和包络分析的滚动轴承故障诊断[J].振动、测试与诊断,2009,29(2):201-204.
Tang Guiji, Cai Wei. Rolling bearings fault diagnosis by using wavelet packet and envelope analysis[J]. Journal of Vibration, Measurement & Diagnosis, 2009,29(2):201-204. (in Chinese)
- [3] 董广明,陈进.基于循环频率能量的滚动轴承损伤程度识别[J].振动工程学报,2010,23(3):249-253.
Dong Guangming, Chen Jin. Damage extent identification of rolling element bearings based on cyclic energy indicator[J]. Journal of Vibration Engineering, 2010,23(3):249-253. (in Chinese)
- [4] 隋文涛,路长, Wang Wilson, 等.基于模拟退火与LSSVM的轴承故障诊断[J].振动、测试与诊断,2010,30(2):119-122.
Sui Wentao, Lu Changhou, Wang Wilson, et al. Bearing fault diagnosis using simulated annealing algorithm and least squares support vector machines[J]. Journal of Vibration, Measurement & Diagnosis, 2010,30(2):119-122. (in Chinese)
- [5] Lempel A, Ziv J. On the complexity of finite sequences[J]. IEEE Transactions on Information Theory, 1976, 22 (1):75-81.
- [6] Pincus S M. Approximate entropy as a complexity measure[J]. Chaos, 1995, 5 (1):110-117.
- [7] Richman J S, Moorman J R. Physiological time series analysis using approximate entropy and sample entropy [J]. American Journal of Physiology-Heart and Circulatory Physiology, 2000, 278(6): 2039-2049.
- [8] Yan Ruqiang, Gao R X. Approximate entropy as a diagnostic tool for machine health monitoring[J]. Mechanical Systems and Signal Processing, 2007,21(2): 824-839.
- [9] Lake D E, Richman J S, Griffin M P, et al. Sample entropy analysis of neonatal heart rate variability[J]. American Journal of Physiology-Regulatory, Integrative and Comparative Physiology, 2002,283(3): 789-797.
- [10] Pincus S M. Assessing serial irregularity and its implications for health[J]. Annals of the New York Academy of Sciences, 2002, 954:245-67.
- [11] Nikolaou N G, Antoniadis I A. Rolling element bearing fault diagnosis using wavelet packets[J]. NDT & E International, 2002, 35(3):197-205
- [12] Alcaraz R, Rieta J J. A review on sample entropy applications for the non-invasive analysis of atrial fibrillation electrocardiograms[J]. Biomedical Signal Processing and Control, 2010, 5(1): 1-14.
- [13] The case western reserve university bearing data center website. Bearing data center seeded fault test data [EB/OL]. [2010-11-05]. <http://cseggroups.case.edu/bearingdatacenter/pages/download-data-file>.
- [14] Zhang Long, Xiong Guoliang, Liu Hesheng, et al. Bearing fault diagnosis using multi-scale entropy and adaptive neuro-fuzzy inference [J]. Expert Systems with Applications, 2010, 37(8): 6077-6085.
- [15] Yang Yu, Yu Dejie, Cheng Junsheng. A roller bearing fault diagnosis method based on EMD energy entropy and ANN[J]. Journal of Sound and Vibration, 2006, 294(1-2): 269-277.
- [16] Hsu C W, Lin C J. A comparison of methods for multi-class support vector machines [J]. IEEE Transactions on Neural Networks, 2002,13: 415-425.



第一作者简介:赵志宏,男,1972年8月生,副教授。主要研究方向为机械故障诊断、非线性动力学、信号处理。曾发表《一种改进的EMD降噪方法》(《振动与冲击》2009年第28卷第12期)等论文。
E-mail:hb_zhaozhong@126.com