

基于小波包近似熵和 SVM 的圆柱滚子轴承诊断*

李学军¹, 何能胜¹, 何宽芳¹, 何雷²
(1. 湖南科技大学机械设备健康维护湖南省重点实验室 湘潭, 411201)
(2. 中南大学高性能复杂制造国家重点实验室 长沙, 410083)

摘要 为了解决特种车辆变速箱圆柱滚子轴承由于振动信号的非线性、非平稳特征较为微弱,提取的特征量数值不明显且现实中难以获得大量含丰富特征的典型故障样本而难以对其进行准确诊断的问题,应用小波包近似熵和支持向量机对特种车辆变速箱圆柱滚子轴承进行诊断。首先,在自行搭建的模拟实验台上采集某型特种车辆变速箱圆柱滚子轴承正常、外圈磨损、滚动体故障、点蚀和压痕 4 种典型状态的振动信号;然后,分别提取 4 种典型状态振动信号的小波包近似熵值作为支持向量机的输入,根据支持向量机的输出结果来确定圆柱滚子轴承是否发生故障和故障类型。结果表明,该方法能有效对某型特种车辆变速箱圆柱滚子轴承的典型状态进行诊断,为其他相似变速箱圆柱滚子轴承的故障诊断提供一种参考途径,具有一定的工程实用价值。

关键词 圆柱滚子轴承;小波包;近似熵;支持向量机;故障诊断
中图分类号 TJ810.7; TH165.3

引 言

圆柱滚子轴承是特种车辆变速箱传动装置的关键部件。设备运行时,磨损、疲劳、腐蚀及过载等原因都可能造成圆柱滚子轴承外圈磨损、滚动体故障、点蚀和压痕等损伤。特种车辆由于运行环境的复杂性,采集的变速箱圆柱滚子轴承振动加速度信号是非线性、时变的,属于典型的非平稳信号,其反映状态信息的能量特征较为微弱,提取的特征量数值区别不明显且现实中难以获得大量含丰富特征的典型故障样本,给特种车辆变速箱圆柱滚子轴承的故障诊断带来了困难。因此,应用一种适用于非平稳振动信号微弱特征的信号特征提取方法和一种具有良好推广特性、适合小样本情况的学习机器进行样本训练,对于特种车辆变速箱中圆柱滚子轴承的故障诊断非常重要。

小波包变换是一种时频分析方法,它具有多分辨率分析的特点,能够提取信号中任意频段的信号,可以实现信号的精细分析,非常适合非平稳信号的处理。熵具有度量信号复杂能力,其大小揭示了观测信号的有序程度。近年来,小波包分析和熵的概念被广泛应用到故障诊断领域。赵志宏等^[1]

将小波包与样本熵相结合,实现了对滚动轴承内圈故障、滚动体故障及外圈故障不同损伤程度下的故障诊断。黄娟等^[2]提出了基于小波包系数近似熵的衰减系数累加和的输电线路故障性质自动识别方法,实现了对超高压输电线路瞬时性故障与永久性故障的自动识别。冯恒椿等^[3]将小波包熵应用到滚动轴承的早期故障诊断中,有效地实现了对轴承早期微弱信号的特征提取。近似熵^[4](approximate entropy,简称 ApEn)作为熵的一种,对瞬态扰动信号不敏感,其所需数据短,具有较好的抗噪声、抗干扰能力^[5-6]。结合特种车辆变速箱圆柱滚子轴承振动信号的非平稳、特征信号微弱的情况,提取振动信号的小波包近似熵作为特征,可以有效表征特种车辆变速箱圆柱滚子轴承的运行状况。

在状态识别方面,神经网络由于需要海量的典型故障样本来进行训练而在实际的工程应用中受到限制。支持向量机(support vector machine,简称 SVM)源于统计学习理论,是一个强大的机器学习分类器。它在解决模式识别的小样本问题中表现出独特的优势和良好的应用前景^[7-8],越来越受到人们的重视。

笔者应用小波包近似熵和 SVM 对某型特种车辆变速箱圆柱滚子典型状态进行诊断。首先,在自行搭建的模拟实验台上采集某型特种车辆变速箱圆

* 国家自然科学基金资助项目(51375262,51175169)
收稿日期:2013-11-29;修回日期:2014-02-24

柱滚子轴承正常、外圈磨损、滚动体故障、点蚀和压痕 4 种典型状态的振动信号;然后,分别提取 4 种典型状态振动信号的小波包近似熵值作为 SVM 的输入,判断轴承的工作状态和故障类型。结果表明,所提取的某型特种车辆变速箱圆柱滚子轴承正常、外圈磨损、滚动体故障、点蚀和压痕 4 种典型状态振动信号的小波包近似熵特征值区别明显,在状态特征样本量较少时也能获得较高的诊断准确率,为某型特种车辆变速箱圆柱滚子轴承典型状态诊断提供了一种实用可行的方案。

1 小波包变换及近似熵分析

1.1 小波包变换

小波包变换是对小波变换的一种改进,是在多分辨分析基础上构成的一种更精细的正交分解方法,能够为信号提供一种更加精细的分析与重构方法。它将频带进行多层次划分,不仅对低频部分进行分解,而且对高频部分也进行分解,并根据被分析信号的特征,自适应地选择频带^[9],从而提高了时频分辨率^[10],非常适合处理非线性和非平稳信号,使得小波包具有更广泛的应用价值。小波包变换选定某种小波函数后,设其滤波系数为 $h=\{h_n\}$,令 $g_k=(-1)^k h_{1-k}$,定义一系列递归函数

$$W_{2n}(t)=\sqrt{2}\sum h_k W_n(2t-k) \tag{1}$$

$$W_{2n+1}(t)=\sqrt{2}\sum g_k W_n(2t-k) \tag{2}$$

由上式所确定的 $\{W_n(t)\}$ 即为小波包, $W_1(t)$ 就是对应的小波函数。小波包对信号的分解结构用树型结构标志。图 1 是以 3 层小波包分解为例说明小波包分解过程。




图 1 小波包分解示意图

Fig. 1 Wavelet packet decomposition diagram

图 1 中,节点 (i,j) 表示第 i 层第 j 个节点 $(i=0,1,2,3;j=0,1,\cdots,7)$,每个节点代表一定的信号特征。其中节点 $(0,0)$ 代表原始信号 S ,节点 $(1,0)$ 代表小波包分解的第 1 层低频系数 x_{10} ,节点 $(1,1)$ 代表小

波包分解的第 1 层高频系数 x_{11} ,其他依此类推。

1.2 近似熵

近似熵是用一个非负数来表示某数据前后的可预测性,以定量描述时间序列的可重复性。越复杂的时间序列对应的近似熵越大,信号越趋于非平稳状态,包含频率成分越丰富,系统越复杂;而近似熵越低,则表示信号越趋于周期性和平稳,信号包含的频谱越窄。

设给定的时间序列为 $\{u(i),i=0,1,\cdots,N\}$,预先给定模式维数 m 和相似容限 r 的值,则近似熵^[11]可以通过以下步骤计算得到。

1) 按序列号连续顺序组成一组 m 维矢量 $\mathbf{X}(i)$,即 $\mathbf{X}(i)=[u(i),u(i+1),\cdots,u(i+m-1)]$ (3)

其中: $i=1\sim N-m+1$ 。

2) 求出矢量 $\mathbf{X}(i)$ 与其余矢量 $\mathbf{X}(j)$ 之间的距离,该距离为矢量 $\mathbf{X}(i)$ 与其余矢量 $\mathbf{X}(j)$ 对应元素中差的绝对值最大的一个,即

$$d[\mathbf{X}(i),\mathbf{X}(j)]=\max_{k=0\sim m-1} u(i+k)-u(j+k) \tag{4}$$

3) 对每一个 i 值,按照给定的阈值 $r(r>0)$,统计 $d[\mathbf{X}(i),\mathbf{X}(j)]<r$ 的数目及此数目与总的矢量个数 $N-m+1$ 的比值,记做 $C_i^m(r)$,即

$$C_i^m(r)=\{d[\mathbf{X}(i),\mathbf{X}(j)]<r\}/(N-m+1) \tag{5}$$

4) 先将 $C_i^m(r)$ 取对数,再求其对所有 i 的平均值,记做 $\Phi^m(r)$,即

$$\Phi^m(r)=\frac{1}{N-m+1}\sum_{i=1}^{N-m+1} \ln C_i^m(r) \tag{6}$$

5) 再对 $m+1$,重复步骤 1~4,得到 $\Phi^{m+1}(r)$ 。

6) 输出此序列理论上的近似熵值 ApEn 为

$$\text{ApEn}(m,r)=\lim_{N\rightarrow\infty} [\Phi^m(r)-\Phi^{m+1}(r)] \tag{7}$$

一般而言,此极限值以概率 1 存在,但在实际中 N 不可能为 ∞ ,当 N 为有限值时,按上述步骤得出的是序列长度为 N 时近似熵值 ApEn 的估计值,记做

$$\text{ApEn}(m,r)=\Phi^m(r)-\Phi^{m+1}(r) \tag{8}$$

ApEn 显然与 m,r 的取值有关。根据经验,通常取 $m=2,r=0.1\sim 0.25\text{SD}(u)$ (SD 表示序列 $\{u(i)\}$ 的标准差),此时近似熵具有较为合理的统计特性^[11]。近似熵算法结果反映了所分析的时间序列信号的复杂程度,而与该信号的幅值大小无关^[12]。算法采用文献^[11]中的快速算法。

近似熵在表征信号复杂性方面具有很强的能力,对机械设备运行状态的诊断具有很好的效果,可以作为机械设备状态检测和故障诊断的一种新的无量纲指标的方法^[13]。结合小波包变换的特点,对小

波包分解后各独立频带信号分量用近似熵来量化故障特征,可以反映不同故障的不规则性和复杂性,从而反映故障信号的非线性、非平稳特征。

2 基于小波包近似熵和 SVM 的圆柱滚子轴承故障诊断

基于小波包近似熵和 SVM 的圆柱滚子轴承故障诊断原理图如图 2 所示,其具体步骤如下。

- 1) 在一定的采样频率下,通过加速度传感器,对圆柱滚子轴承正常、外圈磨损、滚动体故障、点蚀和压痕 4 种状态振动信号分别进行 N 次采样,共获得 $4N$ 个振动信号作为训练样本信号。
- 2) 对每种状态的振动信号进行小波包分解,分别得到 M 个独立的频带,再对每个频带进行特征提取。
- 3) 按照文献[5]中的快速算法提取这 M 个频带的近似熵值 $ApEn_i(i=1,2,\cdots,M)$ 。
- 4) 将这 M 个频带分量近似熵值组成故障特征向量 T

$$T=[ApEn_1, ApEn_2, \cdots, ApEn_M]$$

(9)

对采集到的圆柱滚子轴承正常、外圈磨损、滚动体故障、点蚀和压痕 4 种典型故障状态下的 $4N$ 个训练样本振动信号重复以上的过程,就可以得到 4 个相应的 $N\times M$ 型故障特征向量矩阵。

5) 建立由 4 个支持向量机($SVM_1, SVM_2, SVM_3, SVM_4$)组成的多故障分类器,将提取的各个独立频带分量的近似熵特征向量输入支持向量机,对支持向量机进行训练。

6) 采集测试样本信号,按照步骤 2~4,形成特征向量,作为 SVM 分类器的输入,以 SVM 分类器的输出来确定轴承的工作状态和故障类型。




图 2 基于小波包近似熵和 SVM 的圆柱滚子轴承故障诊断模型

Fig. 2 The fault diagnosis model of cylindrical roller bearing based on wavelet packet approximate entropy and SVM

3 实例应用与分析

为验证应用小波包近似熵和 SVM 对特种车辆变速箱圆柱滚子轴承故障诊断的有效性,所采用的

振动信号来自于自行搭建的模拟实验台。诊断的对象是某型特种车辆变速箱中的圆柱滚子轴承,图 3 为其故障诊断实验系统示意图。

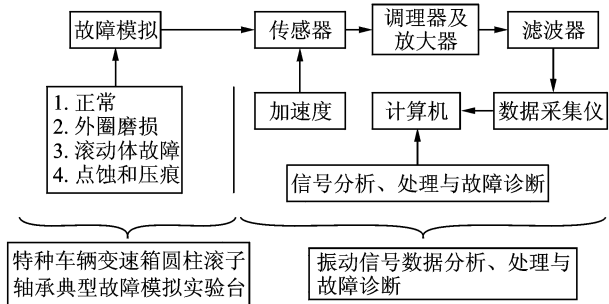


图 3 特种车辆变速箱圆柱滚子轴承故障诊断实验系统
Fig. 3 Special vehicles gearbox cylindrical roller bearing fault diagnosis experiment system

实验在档位为 3 档、采样频率为 20 kHz、电机输出转速为 1 kr/min 和中间输出扭矩为 100 N·m 的工作状况下进行。测点的位置选择在箱体表面比较平坦的地方,这样便于安装和拆卸传感器。本次实验故障轴承均选在输出轴位置的圆柱滚子轴承,测点传感器安装在输出轴轴承正上方。轴承型号为 N218,轴承参数如下:圆柱滚子轴承的平均直径 $D=125.0$ mm;厚度 $B=30.0$ mm;滚动体直径 $d=18.4$ mm;滚子数量 $Z=17$ 。

实验分别测试了某特种车辆变速箱中 N218 圆柱滚子轴承正常、外圈磨损、滚动体故障、点蚀和压痕 4 种典型状态的振动信号。外圈磨损状态是在轴承外圈外表面一圈磨掉 0.15 mm 而成;滚动体故障状态是对轴承的 1 个滚动体磨损 0.15 mm 而成;点蚀和压痕状态是在轴承外圈内表面均等地磨损加工 3 个深度为 0.15 mm 的压痕,如图 4 所示。




图 4 各种故障件
Fig. 4 Various fault pieces

对 4 种典型状态下的振动信号分别采样,各得 50 组数据,在 4 类数据中分别随机抽取 30 组数据作为训练样本数据,将剩余的 20 组数据作为测试样本。外圈磨损振动加速度波形见图 5。




图 5 外圈磨损样本信号
Fig. 5 Outer worn signal

图 6 为采用 db2 小波对外圈磨损故障振动信号进行 3 层小波包分解,然后将分解所得到的各层频带信号进行重构得到的小波包分析图(限于篇幅,仅给出外圈磨损的小波包分析结果,其中 $S(1,0)$ 表示第 1 层[1,0]节点的重构,其他依此类推)。横坐标为采样点数,纵坐标为相应幅值。




图 6 小波包变换主要频段信号重构示意图
Fig. 6 Schematic reconstruction of the main band signal of wavelet packet transform

表 1 轴承各种状态下的部分特征量值
Tab. 1 Part of the feature magnitude of bearing various states

轴承 状态	信号 序号	特征向量(小波包分解第 3 层的 8 个独立频带信号近似熵)							
		ApEn ^{3,0}	ApEn ^{3,1}	ApEn ^{3,2}	ApEn ^{3,3}	ApEn ^{3,4}	ApEn ^{3,5}	ApEn ^{3,6}	ApEn ^{3,7}
正常	1	0.563 8	0.594 5	0.570 3	0.572 6	0.536 0	0.562 4	0.533 2	0.547 4
	2	0.566 1	0.507 1	0.513 6	0.580 7	0.526 6	0.542 1	0.516 7	0.547 6
	3	0.552 9	0.595 1	0.539 4	0.571 1	0.557 3	0.505 4	0.599 4	0.530 7
	4	0.558 0	0.581 9	0.522 9	0.564 2	0.523 7	0.522 8	0.508 5	0.514 1
外圈 磨损	1	0.638 4	0.644 7	0.639 8	0.644 3	0.632 6	0.657 8	0.663 3	0.644 2
	2	0.633 3	0.641 5	0.645 7	0.638 1	0.622 2	0.645 6	0.628 0	0.627 6
	3	0.634 2	0.647 3	0.647 3	0.665 5	0.625 3	0.640 4	0.645 4	0.641 6
	4	0.631 7	0.657 3	0.632 0	0.664 0	0.620 8	0.626 0	0.653 5	0.647 4
滚动体 故障	1	0.667 0	0.693 9	0.697 9	0.709 3	0.663 9	0.695 9	0.664 3	0.694 0
	2	0.670 1	0.686 8	0.661 4	0.609 9	0.681 8	0.706 4	0.605 8	0.704 1
	3	0.679 8	0.702 0	0.696 6	0.708 7	0.656 4	0.716 1	0.614 9	0.661 0
	4	0.678 0	0.667 4	0.662 1	0.666 4	0.689 6	0.680 1	0.671 5	0.674 1
点蚀和 压痕	1	0.599 8	0.602 6	0.609 8	0.604 7	0.608 3	0.615 2	0.594 3	0.585 2
	2	0.615 8	0.618 8	0.620 4	0.621 9	0.576 1	0.596 6	0.543 2	0.637 2
	3	0.592 2	0.621 1	0.600 8	0.627 9	0.627 2	0.592 4	0.594 3	0.582 2
	4	0.604 0	0.616 8	0.614 0	0.623 2	0.558 4	0.588 4	0.580 7	0.598 4

表 2 各种状态下轴承振动信号未经小波包分解的近似熵值

Tab. 2 Bearing vibration signal ApEn of various states without wavelet packet decomposition

轴承状态	信号 1	信号 2	信号 3	信号 4	信号 5	信号 6	信号 7	信号 8	信号 9
正常	0.840 0	0.806 4	0.739 3	0.856 2	0.841 2	0.839 1	0.866 5	0.882 5	0.870 2
外圈磨损	0.899 6	0.923 0	0.912 9	0.911 3	0.978 8	0.982 0	0.908 0	1.019 0	0.944 6
滚动体故障	0.944 9	0.857 3	0.886 6	0.822 9	0.882 3	0.897 9	0.876 6	0.837 4	0.871 4
点蚀和压痕	0.674 7	0.672 2	0.721 2	0.557 2	0.585 0	0.699 9	0.684 4	0.736 3	0.665 3

若直接对各个状态的振动信号求取近似熵,其取值范围差别不明显,有的甚至有重叠,故不经过小波包分解而对原始振动信号直接求取近似熵不能够进行很准确的故障类型的分类。

实验中选取 30 组数据作为训练样本,20 组数据作为测试样本,数据量属于小样本情况。SVM 和 BP 神经网络两类分类器诊断的准确率如表 3 所示。从表 3 可以看出,针对某型特种车辆变速箱圆柱滚子轴承的正常、外圈磨损、滚动体故障、点蚀和压痕 4 种典型状态,BP 神经网络方法的诊断准确率分别为 90%,75%,95%和 75%,SVM 方法的诊断准确率分别为 100%,95%,95%和 100%。测试结果显示,SVM 作为分类器,测试精度比 BP 神经网络性能要好。

通过以上综合对比可以看出,即使是在 4 种典型状态特征样本量较小的情况下,SVM 仍具有较好的诊断效果。应用小波包近似熵和 SVM 的圆柱滚子轴承诊断方法,可以对某型特种车辆变速箱圆柱滚子轴承的正常、外圈磨损、滚动体故障、点蚀和压痕 4 种典型状态进行准确诊断。

表 3 轴承故障诊断测试结果

Tab. 3 The test results of bearing fault diagnosis

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	BP 网络	20	18	2	90
	SVM		20	0	100
外圈磨损	BP 网络	20	15	5	75
	SVM		19	1	95
滚动体故障	BP 网络	20	19	1	95
	SVM		19	1	95
点蚀和压痕	BP 网络	20	15	5	75
	SVM		20	0	100
总数	BP 网络	80	67	13	83.75
	SVM		78	2	97.5

4 结 论

1) 对实验所采集的某型特种车辆变速箱圆柱滚子轴承正常、外圈磨损、滚动体故障、点蚀和压痕 4 种典型状态信号分别提取小波包分解后各频带的近似熵特征,结果表明,不同典型状态信号的小波包近似熵特征值数值范围具有明显的区别。

2) 在状态特征样本量较小的情况下,应用小波包近似熵和 SVM 能有效地对某型特种车辆变速箱圆柱滚子轴承正常、外圈磨损、滚动体故障、点蚀和压痕 4 种典型状态进行故障诊断,且具有较高的正确率。为某型特种车辆变速箱圆柱滚子轴承的故障诊断提供了一种实用可行的途径,也为其他相似变速箱圆柱滚子轴承的故障诊断以及工程实际应用提供一种参考。

参 考 文 献

[1] 赵志宏,杨绍普. 基于小波包变换与样本熵的滚动轴承故障诊断[J]. 振动、测试与诊断, 2012, 32(4): 640-644.

Zhao Zhihong, Yang Shaopu. Roller bearing fault diagnosis based on wavelet packet transform and sample entropy[J]. Journal of Vibration, Measurement & Diagnosis, 2012,32(4):640-644. (in Chinese)

[2] 黄娟,黄纯,江亚群,等. 基于小波包近似熵的线路故障性质辨识方法[J]. 仪器仪表学报, 2012, 33(9): 2009-2015.

Huang Jun, Huang Chun, Jiang Yaqun, et al. Identification method of fault characteristics in transmission lines based on wavelet packet and approximate entropy [J]. Chinese Journal of Scientific Instrument, 2012, 33(9): 2009-2015. (in Chinese)

[3] 冯桓楷,张来斌,石帅,等. 基于小波包熵的轴承状态监测和早期故障诊断技术[J]. 科学技术与工程, 2013, 13(18): 5177-5181.

Feng Huanzhi, Zhang Laibin, Shi Shuai, et al. Fault

- diagnosis of rolling bearing based on wavelet energy entropy [J]. Science Technology and Engineering, 2013, 13(18): 5177-5181. (in Chinese)
- [4] Pincus S M. Approximate entropy as a measure of system complexity [J]. National Academy of Science, 1991, 24: 2297-2301.
- [5] 胡红英, 马孝江. 局域波近似熵及其在机械故障诊断中的应用[J]. 振动与冲击, 2006, 25(4): 38-40, 45.
Hu Hongying, Ma Xiaojang. Local wave approximate entropy and its application in mechanical fault diagnosis [J]. Journal of Vibration and Shock, 2006, 25(4): 38-40, 45. (in Chinese)
- [6] Canales D P, Ramirez J A, Correa J C, et al. Identification of dynamic instabilities in machining process using the approximate entropy method [J]. International Journal of Machine Tool & Manufacture, 2011, 51: 556-564.
- [7] 刘永斌, 何清波, 孔凡让, 等. 基于 PCA 和 SVM 的内燃机故障诊断 [J]. 振动、测试与诊断, 2012, 32(2): 250-255.
Liu Yongbin, He Qingbo, Kong Fanrang, et al. Fault diagnosis of internal combustion engine using PCA and SVM [J]. Journal of Vibration, Measurement & Diagnosis, 2012, 32(2): 250-255. (in Chinese)
- [8] 范劲松, 陶卿, 方廷健, 等. 基于统计学习理论优化感知器的遗传算法 [J]. 模式识别与人工智能, 2001, 14(2): 211-215.
Fan Jinsong, Tao Qing, Fang Tingjian, et al. Genetic algorithm of optimizing perception based on statistical learning theory [J]. Pattern Recognition and Artificial Intelligence, 2001, 14(2): 211-215. (in Chinese)
- [9] Tse P W, Gontarz S, Wang Xiaojuan. Enhanced eigenvector algorithm for recovering multiple sources of vibration signals in machine fault diagnosis [J]. Mechanical Systems and Signal Processing, 2007, 21(7): 2794-2813.
- [10] Sadeghian A, Ye Zhongming, Wu Bin. On line detection of broken rotor bars in induction motors by wavelet packet decomposition and artificial neural networks [J]. IEEE Transactions on Instrumentation and Measurement, 2009, 58(7): 2253-2263.
- [11] 洪波, 唐庆玉, 杨福生, 等. 近似熵、互近似熵的性质、快速算法及其在脑电与认知研究中的初步应用 [J]. 信号处理, 1999, 15(2): 100-108.
Hong Bo, Tang Qingyu, Yang Fusheng, et al. The nature and fast algorithm of approximate entropy, mutual entropy approximate and its preliminary application of EEG and cognitive research [J]. Signal Processing, 1999, 15(2): 100-108. (in Chinese)
- [12] 袁琦, 周卫东, 李淑芳, 等. 基于 ELM 和近似熵的脑电波信号检测方法 [J]. 仪器仪表学报, 2012, 33(3): 517-519.
Yuan Qi, Zhou Weidong, Li Shufang, et al. Brainwave signal detection method that based on ELM and approximate entropy [J]. Chinese Journal of Scientific Instrument, 2012, 33(3): 517-519. (in Chinese)
- [13] 胥永刚, 何正嘉. 分形维数和近似熵用于度量信号复杂性的比较研究 [J]. 振动与冲击, 2003, 22(3): 25-27.
Xu Yonggang, He Zhengjia. Research on comparison between approximate entropy and fractal dimension for complexity measure of signals [J]. Journal of Vibration and Shock, 2003, 22(3): 25-27. (in Chinese)



第一作者简介: 李学军, 男, 1969 年 9 月生, 教授、博士生导师。主要研究方向为机械动力学与故障诊断。曾发表《Model to evaluate the state of mechanical equipment based on health value》(《Mechanism and Machine Theory》2011, Vol. 46, No. 3) 等论文。
E-mail: hnkjdxlj@163.com

