

经验模式分解及关联维数在心音信号分类识别中的应用

郭兴明, 袁志会, 丁晓蓉

(重庆大学生物工程学院 重庆 沙坪坝区 400044)

【摘要】针对心音信号非线性、非平稳的特性,提出一种基于经验模式分解(EMD)和关联维数的心音特征提取方法。首先通过EMD方法将心音信号分解成若干个固有模态函数(IMF),并利用互相关系数准则对IMF进行筛选,结合G-P算法对主IMF(IMF1~IMF4)分量分别求其关联维数,以此作为神经网络的输入向量,实现了对正常心音信号和病理心音信号的分类识别。对于重构相空间中的两个重要参数时间延迟 τ 和关联维数 m ,分别采用互信息函数法和用Cao算法确定。对临床采集的心音数据按该方法进行测试,结果表明,该方法能有效地识别心音。

关键词 关联维数; 经验模式分解; 心音; 神经网络

中图分类号 TP274

文献标志码 A

doi:10.3969/j.issn.1001-0548.2013.06.028

Application of EMD and Correlation Dimension in Classification and Recognition of Heart Sound

GUO Xing-ming, YUAN Zhi-hui, and DING Xiao-rong

(College of Bioengineering, Chongqing University Shapingba Chongqing 400044)

Abstract Focusing on the non-stationary and non-linear of heart sounds, a new method of feature extraction based on empirical mode decomposition (EMD) and Correlation dimension is proposed. The heart sound signals are decomposed into a finite number of intrinsic mode functions (IMFs). The IMF components are chosen by using the criteria of mutual correlation coefficient between IMF components and original signal and then the correlation dimension of the top four intrinsic mode functions (IMF1~IMF4) is calculated by using G-P algorithm. The eigenvectors are put into the artificial neural network for automatic discrimination between normal and abnormal signals. In the process of phase-space reconstruction, Cao theory and the mutual information function are used to determine the two important parameters: delay time and embedding dimension. The clinical data experimental diagnosis and contract test results show that the approach proposed could identify the pathological heart sound effectively.

Key words correlation dimension; empirical mode decomposition; heart sound; neural network

1 介绍

心音信号是人体最重要的生理信号之一,是心脏及心血管系统机械运动状况的反映,其中包含着心脏各部分的生理和病理信息^[1],心音信号的分析与研究对心脏疾病的诊断具有重要的意义。对于心音信号的研究,国内外学者提出了分析识别算法^[2-4],从各种不同的角度研究了心音信号的特点并提取其特征,这些算法对心脏疾病的诊断具有一定的积极意义。但这些研究大多建立在心音信号线性时变或时不变模型基础之上,而心音信号是一种生理非线性、非平稳性振动信号,仅对其进行线性近似及相应的分析,并不能完全揭示心音信号的内在机制。研究表明^[5-8],心音信号为确定的非线性信号,且具

有明显的分形特性。

分形理论是非线性学科中一个活跃的数学分支,以局部和整体具有自相似性的复杂事物为研究对象,探索其复杂性的科学^[9]。近年来,分形理论在心音信号时间序列的研究中取得了一定的进展^[10-12]。分形维数是描述分形特性的重要参数,关联维数作为其中的一种,它的大小及变化可以反映信号的不规则度和复杂度,因其计算过程简单同时又能反映信号的内在联系,被广泛用于非线性系统的定量描述中。文献[6]在心音信号的非线性分析中指出正常心音和几种病理心音的关联维数具有差别。文献[11]利用关联维数,定量的对不同状态下心音信号的复杂程度进行描述,得出不同病理心音信号的关联维数有显著的差别,心音关联维数可作为心音识别的

收稿日期: 2012-06-20; 修回日期: 2012-12-25

基金项目: 国家自然科学基金(30770551); 中央高校基本科研业务费专项基金(CDJXS11230050)

作者简介: 郭兴明(1964-),男,博士,教授,博士生导师,主要从事生物医学信息检测及处理方面的研究。

依据。

上述研究中, 尽管不同心音信号的关联维数具有差异, 但对有些病态心音的关联维数非常接近, 在考虑计算误差的前提下较难区分。鉴于此, 本文拟采用基于经验模式分解(empirical mode decomposition, EMD)和关联维数相结合的心音信号识别方法, 即先对心音信号进行EMD分解, 得到不同频段内的固有模式函数(intrinsic mode function, IMF), 并利用互相关系数准则对IMF进行筛选, 得到主IMF分量, 计算各个IMF分量的关联维数, 作为描述心音信号细节特征的特征向量, 输入神经网络分类器, 实现了正常及异常心音信号的识别。实验结果表明, 本文算法对正常及病理心音信号有较好的识别率, 为心音信号的分类识别提供了一种新的思路。系统整体流程图如图1所示。

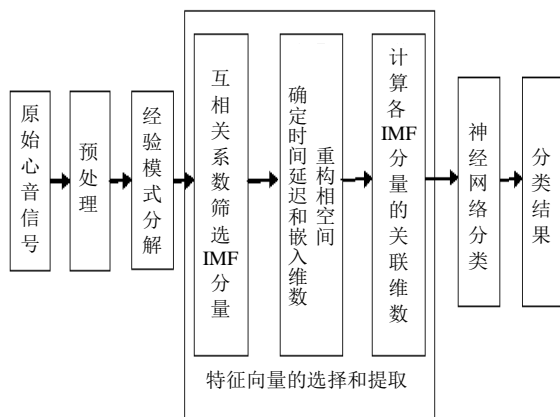


图1 系统流程图

2 EMD的基本原理

EMD方法^[13]是近年来发展起来的处理非线性非平稳性信号的时频分析方法, 其目的是通过对非线性非平稳性复杂信号的分解, 获得一系列表征信号特征时间尺度的IMF分量, 对其进行分析可以更准确地把握原信号的细节特征, 使原信号中包含的信息得到充分的体现。其分解过程如下^[14]: 设时间序列为 $x(t)$, 首先找出 $x(t)$ 的局部极大值和局部极小值, 分别对局部极大值和局部极小值进行3次样条插值构成上下包络曲线, 并求出该包络曲线的均值曲线 $m(t)$, 用 $x(t)$ 减去 $m(t)$, 即有:

$$h_1(t) = x(t) - m(t) \quad (1)$$

将 $h_1(t)$ 作为新的信号重复以上步骤直至进行 k 次循环得到 $h_{1k}(t)$, Huang定义了一个标准差为:

$$S_D = \sum_{t=0}^T \left[\frac{(h_{1(k-1)}(t) - h_{1k}(t))^2}{(h_{1(k-1)}(t))^2} \right] \quad (2)$$

若 $S_D \leq 0.3$, 则第1层分解结束, 定义 $h_{1k} = c_1$, 此时 c_1 即为所求的第一个固有模式分量IMF1, 剩余分量记为 r_1 , $r_1 = x(t) - c_1$ 将 r_1 进行同样的分解过程, 得到 $r_1 - c_1 = r_2$, $r_2 - c_2 = r_3 \dots r_{n-1} - c_{n-1} = r_n$; 若 r_n 局部极值点数少于2, 则整个分解过程结束。原始信号中包含的细节信息通过各个IMF分量得以充分体现, 实现信号特征信息的分离。

EMD方法按频率从高到低依次分解出各个IMF分量, 正常心音以及病理心音之间频有所差异, 所分解出的IMF分量个数也不尽相同, 原信号最显著和有效的信息往往集中在某几个IMF分量中, 加之虚假分量的存在使得IMF筛选成为必然。互相关函数给出了在频域内两个信号是否相关的一个判断指标, 它可以用来确定输出信号有多大程度来自输入信号, 为降低计算量, 利用互相关系数准则计算各IMF分量与原消噪后的信号的互相关系数, 从而确定主IMF分量。在统计学中互相关系数的大小与相关程度有如下对应关系: 相关系数为0.00~±0.30时, 相关程度为微相关; 相关系数为±0.30~±0.50时, 相关程度为实相关; 相关系数为±0.50~±0.80时, 相关程度为显著相关; 相关系数为±0.80~±1.00时, 相关程度为高度相关。

3 关联维数计算及其参数选取

3.1 关联维数的G-P算法

目前, 关联维数的计算主要采用文献[15]提出的“G-P关联维数法”, 该算法较多地应用于心音信号的分析中, 其计算步骤如下:

设 $\{x_k : k=1, 2, \dots, N\}$ 为非线性时间序列, 重构 m 维相空间后得到时间序列的新集合, 其元素记为: $X_n(m, \tau) = (x_n, x_{n+1}, \dots, x_{n+(m-1)\tau})$, $n=1, 2, \dots, N_m$ 。其中, τ 为延迟时间, $\tau = k\Delta t$, Δt 是时间序列的采样时间间隔, k 为整数; N_m 为相空间总点数, $N_m = N - (m-1)\tau$, m 为嵌入维数, N 为信号序列点数。从 N_m 个点中任意选定参考点 X_i , 计算其余 $(N_m - 1)$ 个点到 X_i 的距离为:

$$r_{ij} = d_2(X_i, X_j) \left[\sum_{t=0}^{m-1} (x_{i+t\tau} - x_{j+t\tau})^2 \right]^{\frac{1}{2}} \quad (3)$$

定义关联积分为:

$$C(r) = \frac{2}{N_m(N_m - 1)} \sum_{i,j=1}^{N_m} H(r - r_{ij}) \quad (4)$$

式中, H 是Heaviside函数, 满足:

$$H(r) = \begin{cases} 1 & r > 0 \\ 0 & r \leq 0 \end{cases} \quad (5)$$

关联积分表示重构后的相空间中距离小于标度 r 的矢量点对占有所有矢量点对的比例。对于适当选取的 r , 在无标度区存在如下关系: $C_m(r) \approx r^{D(m)}$, 可以推导出 $D(m) = \lim_{r \rightarrow 0} \frac{\ln C_m(r)}{\ln(r)}$, $D(m)$ 即为关联维数。

3.2 关联维数计算中参数的选取

G-P算法计算时间序列的关联维数时, 时间延迟 τ , 嵌入维数 m 是相空间重构过程中的两个重要参数, 选择合适与否将直接影响所计算关联维数的精确性。

时间延迟 τ 的选取原则是如下: 在不丢失数据信息的情况下, 使数据的自相关程度尽可能小。 τ 值过小, 任意两个相邻的延迟坐标在数值上非常接近, 不能作为两个独立的坐标, 而且导致信息的冗余; 反之, τ 值过大, 任意两个相邻坐标将毫不相关, 不能反映整个系统的特性^[16]。时间延迟 τ 常见的确定方法有自相关法和互信息法。互信息法包含了时间序列的非线性特征, 在非线性时间序列的应用中明显优于自相关法。因此, 本文采用互信息法来计算时间延迟。由于互信息量 $I(\tau)$ 的极小值表示 $x(t)$ 和 $x(t+\tau)$ 是最大可能的不相关, 所以重构时使用 $I(\tau)$ 的第一个极小值点为最优时间延迟, 它能反映出数据点之间的一般特性。

嵌入维数 m 的确定原则是能够描述由时间序列给出的原系统动力学行为的最小维数^[16], 太大的嵌入维数会造成数据的浪费, 太小的嵌入维数又不利于反映真实系统的结构。常见的确定嵌入维数的方法有塔肯斯定理、G-P算法、Cao算法^[17]。本文采用Cao算法来确定嵌入维数, 它是判断伪邻近点的改进方法, 用该方法计算嵌入维数时只需要延迟时间 τ 一个参数, 并且能够有效地区分随机信号和确定性信号, 使用较少的数据就能够求得嵌入维数。

根据Cao算法^[17], 若时间序列确定则存在嵌入维数 m , m 大于某一特定值 m_0 后 $E_1(m)$ 将不再变化。如果时间序列是随机信号, 则 $E_1(m)$ 应逐渐增加, 但在实际应用中对于有限长序列 $E_1(m)$ 不易判断它是缓慢变化的还是已经趋于稳定, 因此, 补充了一个判定随机序列的准则。对于随机序列, 数据间没有相关性, 即不具备可预测性, $E_2(m)$ 将始终为1; 对于确定序列, 数据点之间的相关关系式依赖于嵌入维数 m 值变化的, 总存在一些 m 值使得 $E_2(m)$ 不等于1。

4 神经网络分类器设计

神经网络模型以其良好的非线性映射能力, 自学习能力, 泛化性, 容错性, 鲁棒性被广泛用于模式识别、智能控制等领域。由于BP神经网络可以以任意精度逼近任意的非线性函数, 成为目前应用较为广泛的人工神经网络之一, 标准的BP神经网络因具有收敛速度较慢、易陷入局部极小等缺点, 本文采用一种改进的BP^[18]神经网络建立心音分类的识别模型, 隐含层的传递函数采用双曲正切S型传递函数tansig, 网络训练函数采用尺度化共轭梯度算法(trainscg), trainscg函数是共轭梯度算法的变形。该算法结合了Levenberg-Marquardt算法中的模型置信区间方法和共轭梯度算法, 避免了耗时巨大的线性搜索过程, 从而提高网络的训练速度。

5 心音信号分析

5.1 心音信号的采集和预处理

本文的198例心音数据是利用重庆博精医学信息研究所研制的“运动心力监测仪”在重庆医科大学附属第一医院采集, 包括45例二尖瓣狭窄(mitral stenosis, MS)、42例主动脉瓣狭窄(aortic stenosis, AS)、39例第一心音分裂(splitting of first sound, SFS)和72例正常心音(normal heart sounds, NHS)。采样频率是11.025 kHz, 量化值为8 bit, 最终以wav格式保存采集的信号。全部病理数据经过专家确诊的单一性病例, 健康人群均无心血管和家族病史。

5.2 心音信号预处理

心音信号在采集过程中会引入一些人为及环境干扰带来的噪声, 而噪声也会影响关联维数计算的准确性^[19], 为此, 结合小波函数的性质及心音信号的特点, 本文选用sqtwolog-coif3小波函数对心音信号进行消噪预处理。图2为一例正常心音的去噪效果图, 由图可知, 该消噪方法有效地减少了毛刺等高频信号对波形的干扰, 也为心音关联维数的计算奠定基础。




图2 正常心音信号去噪图

5.3 IMF分量的选取

对于EMD在分解过程中存在端点效应，本文采用信号包络的极值延拓法^[20]抑制。图3是一例二尖瓣狭窄信号去噪后的EMD分解图，共有11个IMF分量，由于篇幅限制只给出前8个分量及残差，从中可以看出EMD分解将心音信号的IMF分量按频率由高到低的顺序依次分离出来，各个IMF包含了不同的时间特征尺度，且随信号自身的变化而变化，使得信号的特征在不同的时间分辨率下显示出来。每阶IMF分量所包含的与原信号相关的信息不同，利用互相关系数准则筛选，各类心音信号相关系数平均值如表1所示，从中可以看出前4个IMF分量与原消噪后的信号的相关性较大，而其他高阶IMF分量与原消噪后的信号的互相关系数皆在0.01或更小的数量级，因此本文取IMF1~IMF4分量的关联维数作为神经网络的输入。

表1 IMF分量与原始信号的互相关系数

心音类型	各个IMF分量与原始信号的相关系数					
	IMF1	IMF2	IMF3	IMF4	IMF5	≥IMF6
NHS	0.479	0.762	0.306	0.103	0.016	<0.01
MS	0.767	0.540	0.368	0.191	0.017	<0.01
AS	0.884	0.368	0.159	0.116	0.008	<0.01
SHS	0.895	0.33	0.207	0.139	0.011	<0.01




图3 一例二尖瓣狭窄的EMD分解图

5.4 心音信号的相空间重构及关联维数

根据互信息法得到一例主动脉瓣狭窄信号的互信息图， $I(\tau)$ 的第一个极小值点为最优时间延迟，如图4所示，其最佳时延 $\tau=5$ 。图5为Cao算法求的E1、E2分布图，由E2的收敛性可进一步证明心音信号的确定非线性，且得到最小嵌入维数为 $m=7$ 。选取 $\tau=5$ ， $m=7$ 计算关联维数得 $D=3.224 1$ 。

为了验证所取 τ 及 m 是否合适，选用G-P算法确定嵌入维数的方法来验证，即根据逐渐增大嵌入维数直至关联维数收敛来确定嵌入维数。图6为在不同嵌入维数下，上例主动脉瓣狭窄信号的 $\ln C_m(r)$ 与 r 的关系图， m 的取值为 $m=\{5, 6, 7, 8, 9, 10, 11, 12\}$ 。计算关联维数依次为 $D=\{2.723 1, 2.989 6, 3.224 1, 3.206 4, 3.272 9, 3.219 0, 3.211 7, 3.201 3\}$ 。从中可以看出随着嵌入维数的增加，关联维数渐渐收敛于一个稳定值， $m>7$ 时关联维数基本保持不变，这与互信息法和Cao算法得出的 m 值一致，验证了所选算法的可行性。




图4 主动脉瓣狭窄互信息图




图5 主动脉瓣狭窄最小嵌入维数




图6 主动脉瓣狭窄的关联积分分布

5.5 实验数据及其分析

各心音信号重构相空间的时间延迟和嵌入维数由互信息法和Cao算法得到。表2所示为预处理后原始心音信号的关联维数D以及各个心音信号经EMD分解后前四阶IMF分量的关联维数均值及方差。

从表中可以看出, 正常心音与病态心音的关联维数值虽然具有差别, 但正常心音与第一心音分裂的关联维数值相近, 二尖瓣狭窄以及主动脉瓣狭窄的关联维数相近, 在误差存在的情况下较难区分。而正常心音的各个IMF的关联维数明显小于病理心音信号的关联维数并且随着分解阶次的升高, 关联

维数值依次递减, 呈现一定的规律性; 二尖瓣狭窄和第一心音分裂IMF2的关联维数明显高于其余各阶, 主动脉瓣狭窄信号的各个IMF分量的关联维数与其他信号相比整体偏大。综合表2数据可以推断, 由于病理机制导致心脏血流发生异常而使相应的心音信号变得复杂, 使得病理心音的复杂程度高于正常心音; 并且各信号IMF分量的关联维数比原始信号单一的关联维数更能描述不同心音信号的内在特征, 这也说明了关联维数能反映信号的复杂程度, 心音信号各IMF分量的关联维数可作为心音信号识别的特征向量。

表2 原始信号及各IMF分量的关联维数

心音类型	D	D _{imf1}	D _{imf2}	D _{imf3}	D _{imf4}
NHS	2.158 4±0.180 2	1.416 5±0.036 1	1.010 6±0.021 2	0.650 7±0.210 4	0.420 2±0.209 1
MS	3.584 3±0.046 9	3.061 2±0.110 1	3.597 1±0.142 8	3.110 2±0.121 6	3.090 5±0.102 9
AS	3.112 4±0.041 7	3.123 0±0.104 3	3.673 4±0.080 3	3.800 2±0.032 1	3.780 1±0.020 7
SHS	2.761 6±0.132 8	2.596 1±0.057 4	2.745 1±0.040 1	2.490 3±0.090 1	2.401 7±0.071 2

6 BP神经网络训练与识别结果

在matlab工具箱中建立BP神经网络模型, 所设计的网络结构如图7所示, 为一个4输入2输出单向传播3层前向神经网络, 隐含层包括11个神经元, 输入向量为各个心音信号IMF1~IMF4的关联维数, 输出矩阵的状态编码为[0,0]、[0,1]、[1,0]、[1,1], 分别对应于正常心音、二尖瓣狭窄、主动脉瓣狭窄、第一心音分裂。选用132个样本(二尖瓣狭窄48例, 主动脉瓣狭窄30例, 第一心音分裂28例, 正常心音26例)作为训练样本, 剩余66例心音为测试样本, 训练集: 测试集=2:1。训练截止误差为0.000 1。神经网络仿真的结果: 对训练集的样本, 均方误差为 8.9266×10^{-4} ,

识别率为100%; 对测试集的样本, 均方误差达到0.001 917, 识别率为92.42%。限于篇幅, 表3给出部分测试样本的识别结果(每种信号选2例)。表4给出文中所选BP神经网络以及标准神经网络对测试集的识别结果, 由此可以看出, 本文所选BP神经网络识别结果明显高于标准BP神经网络的识别结果。




图7 神经网络结构图

表3 基于经验模式分解及关联维数的识别结果

信号类型	输入向量				期望输出	实际输出	分类结果
	D _{imf1}	D _{imf2}	D _{imf3}	D _{imf4}			
NHS	1.430 2	0.990 1	0.821 2	0.570 3	0 0	0.003 8 0.019 3	正确
	1.401 7	1.021 3	0.780 3	0.610 2	0 0	0.005 1 0.004 9	
MS	3.550 3	2.970 6	3.530 4	3.041 5	0 1	0.003 8 0.937 6	正确
	3.612 8	3.110 4	3.611 2	3.180 4	0 1	0.004 3 0.953 7	
AS	3.150 7	3.661 5	3.751 1	3.770 5	1 0	0.961 1 0.005 5	正确
	3.210 4	3.710 6	3.811 4	3.780 4	1 0	0.989 2 0.005 8	
SHS	2.491 0	2.721 5	2.540 7	2.411 3	1 1	0.899 7 0.910 4	正确
	2.621 6	2.710 3	2.550 4	2.452 1	1 1	0.900 6 0.912 4	

表4 测试集识别结果

心音类型	样本总数	本文的BP网络		标准BP网络	
		检测个数	识别率/(%)	检测个数	识别率/(%)
NHS	24	23	95.67	21	87.50
MS	15	14	93.33	12	80.00
AS	14	12	85.71	11	78.57
SHS	13	12	92.31	11	84.62
结果	66	61	92.42	55	83.33

7 结 论

心音信号是一种高度非线性、非平稳性振动信号, 采用传统的线性分析方法不足以揭示心音信号的本质特征, 本文基于非线性分形理论, 提出一种EMD和关联维数结合的心音信号分类识别方法。原

始心音信号经过EMD分解后得到信号的各个IMF分量, 这些IMF分量实现原始信号特征信息的分离, 更能体现原始信号的局部特征信息, 计算与原始信号相关性较大的IMF分量的关联维数, 结果表明, 所得关联维数及其变化规律能更细致地描述心音信号的细节特征, 可以作为心音信号分类识别的特征向量。结合改进的BP神经网络所建立的模型, 可以有效地对不同心音信号进行识别, 为心音信号的分类识别提供了一种新的方法。由于心音信号的非线性分形机制还在探索当中, 仅仅依靠关联维数尚不足以完全揭示心音信号的内在本质特性, 因此还需要做进一步的研究, 如与传统的心音特征参数结合以及采用多尺度分形方法等, 以便进一步提高识别率, 这也是下一步研究的重点。

参 考 文 献

- [1] 陈剑, 郭兴明, 肖守中. 心音信号识别的意义及其方法的研究[J]. 国外医学(生物医学工程分册), 2004, 27(2): 87-89.
CHEN Jian, GUO Xing-ming, XIAO Shou-zhong. Study on signification and method of heart sound recognition[J]. Biomedical Engineering Foreign Medical Sciences, 2004, 27(2): 87-89.
- [2] JIANG Zhong-wei, SAMJIN Choi, WANG Hai-bin. A new approach on heart murmurs classification with SVM technique[C]//The 2007 International Symposium on Information Technology Convergence. Los Alamitos: [s.n.], 2007: 240-244.
- [3] UGUZ H, ARSLAN A, TURKOGLU I. A biomedical system based on hidden markov model for diagnosis of the heart valve diseases[J]. Elsevier, Pattern Recognition Letters, 2007(28): 395-404.
- [4] KUMAR D, CARVALHO P, ANTUNES M, et al. Discrimination of heart sounds using chaos analysis in various subbands[C]//Proceedings of the International Conference on Bio-inspired Systems and Signal Processing. SETUBAL: [s.n.], 2009: 369-375.
- [5] LI B B, YUAN Z F. Non-linear and chaos characteristics of heart sound time series[J]. Proceedings of the Institution of Mechanical Engineers, Part H: Journal of Engineering in Medicine, 2008, 222(3): 265-272.
- [6] GNITECKI J, MOUSSAVI Z. Variance fractal dimension trajectory as a tool for heart sound localization in lung sounds recording[C]//25th Annual International Conference of the IEEE Engineering in Medicine and Biology Society. New York: IEEE, 2003: 2420-2423.
- [7] MANDELBORT B B. The fractal geometry of nature[M]. San Francisco: W H Freeman, 1982.
- [8] CARVALHO P, GIL P, HENRIQUES J, et al. Low complexity algorithm for heart sound segmentation using the variance fractal dimension[C]//2005 IEEE International Workshop on Intelligent Signal Processing. New York: IEEE, 2005: 194-199.
- [9] 周静, 何为. 基于关联维数的心音分析研究[J]. 现代科学仪器, 2007(2): 56-59.
ZHOU Jing, HE Wei. Studies on sound with correlation dimension[J]. Modern Scientific Instruments, 2007(2): 56-59.
- [10] 贾丽会, 张修如. 基于盒维数的心音信号分形特征研究[J]. 生物数学学报, 2009, 24(2): 379-383.
JIA Li-hui, ZHANG Xiu-ru. Research on fractal characteristics of heart sound signals based on box-counting dimension[J]. Journal of Biomathematics, 2009, 24(2): 379-383.
- [11] HUANG N E, SHEN Z, LONG S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[J]. Proc R Soc Lond A, 1998(454): 903-995.
- [12] 王祝平, 王为, 李小昱, 等. 基于EMD与神经网络的内燃机气门间隙故障诊断[J]. 农业机械学报, 2007, 38(12): 134.
WANG Zhu-ping, WANG Wei, LI Xiao-yu, et al. Fault diagnosis of engine valve based on EMD and artificial neural network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2007, 38(12): 134.
- [13] GRASSBERGER P, PROCACCIA I. Measuring the strangeness of strange attractors[J]. Physica D: Nonlinear Phenomena, 1983, 9(1-2): 189-208.
- [14] 滕丽娜, 刘天雄, 佟德纯, 等. 关联维数在设备状态检测中的应用研究[J]. 振动工程学报, 2002, 15(4): 399-401.
TENG Li-na, LIU Tian-xiong, TONG De-chun, et al. Application of correlation dimension to machinery condition monitoring[J]. Journal of Vibration Engineering, 2002, 15(4): 399-401.
- [15] 张淑清, 贾健, 高敏, 等. 混沌时间序列重构相空间参数选取研究[J]. 物理学报, 2010, 59(3): 1576-1579.
ZHANG Shu-qing, JIA Jian, GAO Min, et al. Study on the parameters determination for reconstructing phase-space in chaos time series[J]. Acta Physica Sinica, 2010, 59(3): 1576-1579.
- [16] 胡方明, 简琴, 张秀君. 基于BP神经网络的车型分类器[J]. 西安电子科技大学学报(自然科学版), 2005, 32(3): 399-441.
HU Fang-ming, JIAN Qin, ZHANG Xiu-jun. The classifier of car types using BP neural networks[J]. Journal of Xidian University(Natural Science), 2005, 32(3): 399-441.
- [17] 李琳, 张永祥, 明延涛. EMD降噪的关联维数在齿轮故障诊断中的应用研究[J]. 振动与冲击, 2009, 28(4): 145-146.
LI Lin, ZHANG Yong-xiang, MING Yan-tao. Gear fault diagnosis based on correlation dimension pre-processed with EMD[J]. Journal of Vibration and Shock, 2009, 28(4): 145-146.
- [18] 黄大吉, 赵进平, 苏纪兰. 希尔伯特-黄变换的端点延拓[J]. 海洋学报, 2003, 25(1): 1-11.
HUANG Da-ji, ZHAO Jin-ping, SU Ji-lan. Practical implementation of the Hilbert-Huang transform algorithm[J]. Acta Oceanologica Sinica, 2003, 25(1): 1-11.

编辑 黄莘