

高速列车转向架故障信号的聚合经验模态分解和模糊熵特征分析

秦 娜^{1†}, 金炜东¹, 黄 进¹, 李智敏²

(1. 西南交通大学 电气工程学院, 四川 成都 610031; 2. 西南交通大学 材料科学与工程学院, 四川 成都 610031)

摘要: 为了对高速列车转向架关键部件进行状态监测, 利用转向架故障振动信号的特点, 提出了一种结合聚合经验模态分解和模糊熵的特征提取方法. 对故障信号进行聚合经验模态分解, 得到一系列具有不同物理意义的简单成分信号, 采用相关分析法选取最能反映原信号特征的本征模态函数. 对这些本征模态函数和原信号分别计算模糊熵值构成多尺度复杂性度量的特征向量, 输入最小二乘支持向量机中进行分类识别, 与模糊熵特征相比得到了更好的识别效果, 证明了算法的有效性.

关键词: 高速列车转向架; 特征提取; 聚合经验模态分解; 模糊熵; 最小二乘支持向量机

中图分类号: TP274; TP391.4

文献标识码: A

Ensemble empirical mode decomposition and fuzzy entropy in fault feature analysis for high-speed train bogie

QIN Na^{1†}, JIN Wei-dong¹, HUANG Jin¹, LI Zhi-min²

(1. School of Electrical Engineering, Southwest Jiaotong University, Chengdu Sichuan 610031, China;

2. School of Materials Science and Engineering, Southwest Jiaotong University, Chengdu Sichuan 610031, China)

Abstract: To monitor the working condition of key components in a high-speed train bogie, we make use of the characteristics of the fault signal to propose a new approach for feature extraction based on ensemble empirical mode decomposition and fuzzy entropy. Firstly, we decompose the fault vibration signal by using the ensemble empirical mode decomposition to obtain a series of simple composition signal with different physical significance. Then, we employ the correlation analysis to sift out intrinsic mode functions (IMF) that have largest correlation coefficients with the original signal and use it as the data source. The fuzzy entropy of IMF and the fuzzy entropy of the initial signal are calculated to form a multi-scale complexity measure feature vector. Finally, the feature vector is put into the least squares support vector machine for classification and identification. Comparing with the fuzzy entropy, we find the proposed approach gives better fault identification results. The efficacy of this method is validated.

Key words: high speed train bogie; feature extraction; ensemble empirical mode decomposition (EEMD); fuzzy entropy; least squares support vector machine (LSSVM)

1 引言(Introduction)

高速列车转向架是连接车体和轨道的重要机构, 其机械性能的恶化轻则导致振动加剧、舒适性降低, 重则导致列车运行失稳, 脱轨翻车等严重安全事故^[1]. 目前, 对高速列车转向架机械故障的研究多是通过动力学模型中参数的改变模拟转向架机械部件的性能退化和失效状态, 分析转向架机械故障对车辆运行稳定性和临界速度的影响^[2-3]. 随着在线监测技术的不断发展完善, 得到的海量监测数据中蕴含了反映转向架机械性能的丰富信息, 因此, 开展基于数据的高速列车转向架故障诊断具有非常重要的现实意义.

机械故障振动信号由于受到结构形变、速度突变等随机因素的影响, 往往呈现出典型的非线性非平稳特征, 因此传统的时频分析方法往往不能很好地分析这类信号的特征. 小波变换作为一种时频分析方法近年来被用于多个领域并取得了很好的效果^[4], 但是存在小波基、分解层数选择困难和对参数敏感等问题. 经验模态分解(empirical mode decomposition, EMD)是一种自适应的时频分析方法, 根据信号的局部特征自适应地选择分解层数和尺度, 非常适合非线性非平稳信号的分析^[5]. 但对于含有冲击成分的信号, 往往会造成严重的模式混叠现象^[6], 聚合经验模态分解(ensemble empirical mode decomposition, EEMD)

作为EMD的改进算法很好地解决了这些问题^[7-8].

熵是用于描述系统的复杂程度及产生新状态的能力. 熵的值越大, 表明系统的复杂度越高, 越紊乱, 系统就越具有不规则性. 模糊熵(fuzzy entropy)是在模糊理论的基础上提出的, 是对近似熵和样本熵算法的改进, 并被成功地运用于表面肌电信号序列的复杂度特征提取^[9].

目前的文献都是在原始时域信号的基础上计算模糊熵作为反映信号复杂度和随机性的特征参数^[10-11]. 本文的研究对象高速列车转向架机械系统是典型的复杂非线性系统, 列车车体和构架上的振动信号受到轨道激励和转向架上机械部件状态的共同影响, 存在复杂的非线性耦合关系. 振动信号中包含了轨道激励引起的振动, 转向架关键部件故障状态引起的振动, 车体的固有振动等. 因此, 仅仅提取原始混合信号的模糊熵不能全面反映信号各模态组份的细节特征. 针对高速列车转向架故障振动信号的特点, 将聚合经验模态分解和模糊熵信息测度相结合用于高速列车转向架故障振动信号的多尺度特征提取. 聚合经验模态分解后的本征模态函数(intrinsic mode functions, IMFS)是具有特定物理含义的振动信号, 利用相关系数法选取与原信号最相关的模态成分来提取模糊熵, 可以更好地反映信号在不同尺度和物理意义上信号的细节复杂度特征. 最后采用最小二乘支持向量机(least squares support vector machine, LSSVM)进行故障状态识别, 通过大量的实验分析证明了该方法的有效性.

2 聚合经验模态分解(Ensemble empirical mode decomposition)

列车系统振动与行车速度和轨道激励有关, 存在复杂的耦合关系, 其振动信号属于非平稳随机信号. 当高速列车发生故障时, 振动信号往往会包含比较多的冲击成分, 为了有效地抑制EMD分解过程中的模态混叠现象, Huang和Wu于2009年提出了聚合经验模态分解^[12].

EEMD就是将每个原始信号中加入有限幅值的高斯白噪声, 是基于白噪声的统计特性在分解中呈现为自适应二滤波器. 算法的基本原理是^[8, 13]: 白噪声被添加在时频空间的各个不同尺度的组成成分中, 不同尺度的信号就会自动投影到一个由白噪声建立的合适的尺度空间中. 利用白噪声多次试验相抵消的统计特性, 可以采取求平均值的方法来抑制分解结果中噪声的影响.

EEMD算法的步骤为:

步骤1 初始化聚合次数 N , 高斯白噪声的幅值系数 k , 并且使 $m = 1$;

步骤2 计算第 m 次在信号中加入高斯白噪声

后的实验信号

$$x_m(t) = x(t) + k \cdot n_m(t); \quad (1)$$

步骤3 利用经验模态分解将加入白噪声后的信号分解为一组本征模态函数;

步骤4 当 $m < N$ 时, 重复步骤2和3, 每次加入不同的白噪声信号, 并使 $m = m + 1$;

步骤5 计算 N 次分解出的各个IMFS均值

$$\bar{c}_i = \sum_{m=1}^N c_{i,m}/N, \quad (2)$$

N 为经验模态分解的聚合次数; $c_{i,m}$ 为由第 m 次分解得到的第 i 个IMF;

步骤6 取每个IMF的 N 次分解的均值作为最终的本征模态函数.

通过以上步骤, EEMD方法有效地克服了模式混叠问题, 对传统的经验模态分解进行了重要改进.

3 模糊熵特征提取(Fuzzy entropy feature extraction)

模糊熵是近似熵和样本熵的改进算法, 它们的物理意义类似都是时间序列复杂性度量, 反映了序列产生新模式的概率, 熵值越大系统复杂度越高, 产生新模式的概率越大^[14-15]. 模糊熵将模糊集合理论引入序列复杂性的计算, 利用指数函数将相似性度量模糊化, 使得模糊熵的值能够随参数稳定变化. 与近似熵和样本熵相比, 模糊熵对重构相空间的维数和相似容限等参数的依赖性、敏感性更低, 在测度值的连续性和对序列长度的一致性方面都有更好的表现^[10].

模糊熵的计算方法如下:

已知一个长度为 N 的时间序列 $\{u(1), u(2), \dots, u(N)\}$, 定义一个非负的整数 m 满足 $m \leq N - 2$, 对原始时间序列 u 进行相空间重构后得到一个新的序列:

$$s^m(i) = \{u(i), u(i+1), \dots, u(N) - u_0(i), \quad (3)$$

式中 $i = 1, 2, \dots, N - m + 1$, 且

$$u_0(i) = \frac{1}{m} \sum_{j=0}^{m-1} u(i+j).$$

模糊理论中定义的模糊隶属度函数为

$$A(x) = \begin{cases} 1, & x = 0, \\ \exp[-\ln 2 (\frac{x}{r})^2], & x > 0, \end{cases} \quad (4)$$

式中的 r 为相似容限. 由上式可得模糊隶属度函数为

$$A_{ij}^m = \exp(-\ln 2 \cdot (\frac{d_{ij}^m}{r})^2), \quad (5)$$

式中的 d_{ij}^m 表示 $s^m(i)$ 和 $s^m(j)$ 两个重构向量之间的距离, 即

$$d_{ij}^m = d[s^m(i), s^m(j)] =$$

$$\max_{p=1,2,\dots,m} (|u(i+p-1) - u_0(i)| - |u(j+p-1) - u_0(j)|). \quad (6)$$

定义

$$C_i^m(r) = (N-m)^{-1} \sum_{j=1, j \neq i}^{N-m+1} A_{ij}^m,$$

同时定义

$$\Phi^m(r) = (N-m+1)^{-1} \sum_{i=1}^{N-m+1} C_i^m(r).$$

时间序列的模糊熵定义为

$$\text{FuzzyEn}(m, r, N) = \ln \Phi^m(r) - \ln \Phi^{m+1}(r), \quad (7)$$

式中: m 为重构相空间的维数, r 为相似容限, N 为被分析时间序列的长度.

在参数选择方面, 重构相空间的维数 m 越大, 越能够细致地反映重构相空间中信号的动态演变过程. 对于相似容限 r 的选择也需要慎重, 过小的 r 值会导致模糊熵特征对原始序列中的噪声敏感, 过大的 r 则会导致信号中原始信息的大量丢失. 通常情况下, 相似容限的选择与原始时间序列的标准差 (standard deviation, SD) 成正比, 一般取 r 为 $r \times \text{SD}$. 在后面的叙述中, 如果取 $r = 0.3$ 就代表 $r = 0.3 \times \text{SD}$.

4 最小二乘支持向量机 (Least squares support vector machine)

对信号进行 EEMD 分解后得到含有不同频带成分的本征模态函数, 分别计算模糊熵值组成高维特征向量能够在多尺度上反映系统的复杂程度. 为了实现高速列车转向架故障的自动分类识别, 考虑采用基于统计学习理论和结构风险最小化原则的支持向量机. 由于本文采用的仿真实验本身计算量巨大, 实验条件所限得到的样本数非常有限, 而支持向量机恰恰适合于这样的小样本分类问题. 最小二乘支持向量机 (LSSVM) 是在标准支持向量机基础上提出的一种新的机器学习算法^[16], 采用二次损失函数将 SVM 中的二次规划问题转换为线性方程组求解问题, 在降低算法复杂度的同时保证了计算的精度, 相比标准 SVM 大大提高了识别部分的运算效率. 已经被广泛地应用于多个领域的模式识别、故障诊断及故障预测, 并取得了很好的效果.

LSSVM 的优化目标为

$$\min_{w, b, \xi} J_{\text{LS}}(w, \xi) = \frac{1}{2} \|w\|^2 + \frac{\gamma}{2} \sum_{i=1}^n \xi_i^2, \quad (8)$$

$$\text{s.t. } y_i[w^T \varphi(x_i) + b] = 1 - \xi_i, \quad i = 1, 2, \dots, n,$$

式中: γ 为惩罚系数, 是为了对 $J_{\text{LS}}(w, \xi)$ 进行控制; w 为权向量; ξ_i 为松弛因子.

引入拉格朗日函数, a_i 为拉格朗日乘子, 上述的优化问题就转化为一个线性方程组的求解问题:

$$\begin{bmatrix} I & 0 & 0 & -Z^T \\ 0 & 0 & 0 & -Y^T \\ 0 & 0 & \gamma I & -I \\ Z & Y & 0 & 0 \end{bmatrix} \begin{bmatrix} w \\ b \\ \xi \\ a \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ 0 \\ \vec{I} \end{bmatrix}, \quad (9)$$

其中:

$$Z = [\varphi(x_1)^T y_1 \quad \varphi(x_2)^T y_2 \quad \dots \quad \varphi(x_n)^T y_n]^T,$$

$$Y = [y_1 \quad y_2 \quad \dots \quad y_n]^T, \quad \vec{I} = [1 \quad \dots \quad 1]^T,$$

$$\xi = [\xi_1 \quad \xi_2 \quad \dots \quad \xi_n]^T, \quad a = [\alpha_1 \quad \alpha_2 \quad \dots \quad \alpha_n]^T,$$

$I \in \mathbb{R}^{n \times n}$ 是单位矩阵. 消去 w 和 ξ , 上面的方程组可以简化为

$$\begin{bmatrix} 0 & Y^T \\ Y & ZZ^T + \gamma^{-1} I \end{bmatrix} \begin{bmatrix} b \\ a \end{bmatrix} = \begin{bmatrix} 0 \\ \vec{I} \end{bmatrix}, \quad (10)$$

式中:

$$ZZ^T = [q_{ij}]_{n \times n},$$

$$q_{ij} = y_i y_j \varphi(x_i)^T \varphi(x_j) = y_i y_j K(x_i x_j),$$

$K(x_i x_j)$ 为径向基核函数

$$K(x_i x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{\sigma^2}\right).$$

利用最小二乘法求解式(10), 得到线性分类器

$$y(x) = \text{sgn}\left[\sum_{i=1}^n \alpha_i y_i \varphi(x_i) + b\right].$$

采用最小二乘支持向量机的一对多算法, 针对高速列车转向架的4种典型故障构造3个2分类器. 每个分类器的训练样本都分为正样本和负样本, 3个分类器构成二叉树结构实现多故障的分类识别.



5 高速列车转向架故障信号分析 (Fault signal analysis of high speed train bogie)

5.1 数据来源及实验方案 (Data sources and experimental program)



实验数据均来自西南交通大学牵引动力国家重点实验室, 基于多体动力学分析软件 simpack, 建立某动车组车辆系统非线性动力学模型, 车轮踏面外形采用 LMA 踏面, 钢轨采用 CN60 钢轨, 轮对内侧局沿用中国标准 1353 mm, 充分考虑轮轨接触几何非线性、轮轨蠕滑非线性和非线性悬挂, 该列车模型由 1 个车体、2 个构架、4 个轮对、8 个转臂和 2 个牵引拉杆, 全车共 62 个自由度, 仿真采用武汉-广州客运专线实测轨道激励谱进行分析. 转向架故障工况主要涉及横向减振器故障、抗蛇行减振器故障、空气弹簧失气和原车方案 (无故障状态). 每种工况下运行速度按照 40 km/h, 80 km/h, 120 km/h, 140 km/h, 160 km/h, 200 km/h, $\dots$ 递增, 直至失稳. 每种速度下运行 3.6 min, 传感器采样频率为 243 Hz.

仿真实验记录列车及转向架上各相关部位的振动信号, 主要包括车体、构架、轴箱上各部位横向、纵向



和垂向振动加速度和车体、构架、轮对、一系、二系各部位3个方向的振动位移,共得到58个传感器通道数据.图1为高速列车转向架的4种典型工况振动信号时域和幅值谱图,图中:(a)为原车;(b)为空气弹簧失气;(c)为抗蛇行减振器故障;(d)为横向减振器故障.





(a) 原车



(b) 空气弹簧失气



(c) 抗蛇行减振器故障



(d) 横向减振器故障

图1 4种典型工况的时域信号和幅值谱

Fig. 1 Time-domain signal and amplitude spectrum of four working conditions

5.2 信号处理流程(Signal processing flows)

由车辆动力学原理可知,列车转向架故障振动信号是典型的非线性非平稳信号,故障特征主要体现在低频部分,首先将原始振动信号进行小波包消噪处理;然后对消噪后的信号进行聚合经验模态分解,根据信号自身的特点自适应地分解为一系列成分简单的本征模态函数,这些IMFS按照频段从高到低的顺序排列;对原始信号和EEMD分解得到的IMFS分别计算反映各尺度信号复杂度特征的模糊熵测度值,组成高维特征向量;将高维特征向量输入到最小二乘支持向量机中进行分类识别,得到高速列车转向架的故障状态识别结果.图2为信号处理流程图.



图2 信号处理流程图

Fig. 2 Signal processing flow chart

5.3 信号的聚合经验模态分解(Signal's ensemble empirical mode decomposition)

消噪后的振动信号采用EEMD进行分解,图3为横向减振器故障状态下构架上1架1位横向振动加速度信号的EEMD分解结果中前8个IMFS分量.理想情况下,每个IMF都是一个简单平稳信号,代表原信号中的特征成分之一.但由于受到包络估计函数、白噪声幅值系数、聚合迭代次数等参数选择的影响,分解结果中不可避免地存在虚假成分.为了从IMFS中选取最能反映原信号特征的分量,采用相关系数法求出各IMFS与原信号的相关系数.结果表明,前6个IMFS与原信号的相关系数均大于0.1,后面的IMFS相关系数均小于0.1,并且呈逐层降低趋势.因此,选取原信号和EEMD分解后的前6个IMFS作为模糊熵特征提取的信号.




图3 信号EEMD分解结果

Fig. 3 Decomposition result by EEMD


5.4 模糊熵特征提取(Fuzzy entropy feature extraction)

模糊熵的计算中, 参数的选择对熵值的计算结果会产生很大影响. 重构相空间维数 m 的值越大越能体现信号动态演化的过程. 相似容限 r 过大会加剧信息的丢失, 过小则会增加噪声敏感性并导致熵值不确定性增加. 按照经验, 选取 $m = 2$, $r = 0.3$, 计算原始信号和EEMD分解后的前6个IMFs的模糊熵值. 4种工况的各尺度模糊熵计算结果如表1所示.


表1 4种工况的各尺度模糊熵特征值
Table 1 Multiscale fuzzy entropy of four working conditions

	原信号	IMF1	IMF2	IMF3	IMF4	IMF5	IMF6
原车	0.325	0.168	0.136	0.085	0.021	0.002	0.001
空气弹簧失气	2.742	0.897	0.878	0.190	0.029	0.002	0.001
抗蛇行减振器失效	0.619	0.387	0.257	0.140	0.046	0.001	0.000
横向减振器失效	1.608	6.463	1.452	0.703	0.244	0.069	0.010

运行速度200 km/h下, 对4种工况的仿真数据各截取70个样本信号, 每个样本729个采样点. 对所有的样本计算EEMD分解后的各尺度模糊熵特征, 构成 280×7 的特征矩阵. 图4给出了车体前部横向位移信号的模糊熵特征在三维特征空间中的分布情况. 由图可知, EEMD模糊熵特征在高维特征空间上拥有良好的类内聚集性和类间分离性, 这是后面分类识别的基础.



(a) 第1, 2, 3维模糊熵特征



(b) 第5, 6, 7维模糊熵特征

图4 模糊熵特征的三维空间散点图

Fig. 4 Scatter diagram of fuzzy entropy in 3-D feature space

5.5 最小二乘支持向量机故障状态识别(Least squares support vector machine for fault condition recognition)

由于计算量巨大,仿真实验得到的样本数比较有限,为了实现高速列车转向架故障状态自动的分类识别,采用最小二乘支持向量机作为分类器.最小二乘支持向量机比传统支持向量机在不降低识别精度的前提下具有更快的收敛速度.将前面得到的7维EEMD模糊熵特征向量作为最小二乘支持向量机的输入,运行速度为200 km/h下识别率如表2所示,同时与模糊熵和EEMD近似熵特征提取方法做了比较.结果表明,特征提取环节中EEMD的引入使得特征能从多个尺度上反映信号的内在特点,相比只针对原始信号提取熵特征大幅提高了识别率.EEMD近似熵与EEMD模糊熵方法在各通道均有很好的表现,

EEMD模糊熵识别率略高,体现了模糊熵算法在振动信号处理中的优越性.

目前较常用的分类器中,BP神经网络需要大量的训练样本,由于条件所限,本文仿真实验得到的样本数非常有限因此会导致神经网络分类器的识别精度不高,识别率不稳定等问题.SVM是基于结构风险最小化原则的机器学习方法,适合于高维小样本非线性数据的分类问题.最小二乘SVM在不降低SVM的识别精度的基础上大大缩短了训练和测试时间.表3为3种分类器识别效果对比结果.表中数据为10次相同条件下实验所得结果的均值.实验结果表明,BP神经网络由于受到样本数量的限制而影响到识别效果,识别率偏低并且不够稳定.SVM和LSSVM识别率和稳定性都有很好的表现,其中LSSVM效率更高.

表 2 不同特征不同位置的识别率比较

Table 2 Recognition rate of different feature in different positions

识别率/%	构架1架4位 横向加速度	构架1架中部 横向加速度	构架2架5位 横向加速度	车体前部 横向位移	车体中部 横向位移	车体后部 横向位移
模糊熵	83.9	83.9	81.3	67.8	68.7	72.3
EEMD近似熵	96.2	99.3	95.1	98.2	96.4	98.2
EEMD模糊熵	98.2	100	96.4	98.2	99.1	100

表 3 3种分类器识别效果对比

Table 3 Result contrast of three classifiers

	训练时间/s	识别率/%	测试时间/s	识别率的 方差
BP神经网络	0.93	5×10^{-3}	91.9	11.59
SVM	4.29	0.46×10^{-3}	99.2	2.90
LSSVM	0.044	0.1×10^{-3}	98.8	3.97

5.6 参数渐变故障的EEMD模糊熵特征(EEMD fuzzy entropy feature of gradual failure)

在实际运行的机械系统中,阻尼部件的性能参数蜕化往往是一个渐变的过程,因此探讨机械部件的参数蜕化与振动信号特征之间的关系是很有意义的.为了探讨高速列车转向架上关键阻尼部件参数蜕化体现在EEMD模糊熵特征的变化规律,实验选取抗蛇行减振器故障作为例子进行了仿真计算,在其他运行条件相同的情况下,依次改变抗蛇行减振器的阻尼参数90%,80%, $\dots$,10%.每种参数下选取30个样本,每个样本包含729个采样点.按照前面的方法进行预处理和特征提取,图5为1位抗蛇行相对位移信号在抗蛇行减振器故障参数渐变时EEMD模糊熵特征的三维空间散点图.




图 5 故障参数渐变时特征在三维空间上的散点图
Fig. 5 Scatter diagram of fuzzy entropy with change fault parameter

从图5可以看出特征跟随故障参数蜕化而渐变的过程,在故障的初期阶段即故障阻尼为正常阻尼的90%到50%时特征值变化不明显,证明阻尼参数蜕化的初始阶段对整个列车机械系统的影响不大.随着故障参数的进一步恶化,特征的变化也随之加剧,阻尼30%到10%对应的特征在空间上明显不同,说明此时机械部件阻尼参数的微小变化对系统的影响进一步加剧,此时抗蛇行减振器已接近失效状态.

分析表明, EEMD模糊熵特征的变化很好地反映了整个故障参数蜕化过程。

6 结论(Conclusions)

聚合经验模态分解是一种新的时频分析方法, 非常适合非线性非平稳的复杂信号, 能够根据信号自身的特点自适应地选择分解的层数和频带, 将信号分解为一系列简单成分的近似平稳信号, 同时很好地克服了传统经验模态分解的模式混叠、端点效应等问题。模糊熵是从在近似熵和样本熵的基础上发展而来的, 相比这两种熵具有参数敏感性更低, 测度值稳定性鲁棒性更高的优点。对EEMD分解后的本征模态函数计算模糊熵, 得到多个尺度上故障信号的复杂性度量, 为高速列车转向架机械故障信号分析提供了良好的依据。采用最小二乘支持向量机对高速列车转向架上4种典型工况的信号进行了分类识别, 在运行速度为200 km/h时多个通道上得到了95%以上的识别率。最后分析了特征随故障参数渐变的变化趋势下特征的表现, 验证了算法对高速列车转向架故障分析的有效性。

本文的仿真实验和数据处理只涉及到高速列车转向架关键部件的单故障识别, 在列车实际运行过程中有可能会发生多种故障的并行和混合, 因此, 多故障信号的分离是今后研究需要关注和解决的一个重要问题。

参考文献(References):

- [1] 大庭拓也. 基于振动分析的新干线转向架的状态监视[J]. 国外铁道车辆, 2013, 50(3): 32 – 40.
(DATING Tuoye. The condition monitoring for shinkansen bogies based on vibration analysis [J]. *Foreign Rolling Stock*, 2013, 50(3): 32 – 40.)
- [2] 张卫华, 李艳, 宋冬利. 高速列车运动稳定性设计方法研究[J]. 西南交通大学学报, 2013, 48(1): 1 – 9.
(ZHANG Weihua, LI Yan, SONG Dongli. Design methods for motion stability of high-speed trains [J]. *Journal of Southwest Jiaotong University*, 2013, 48(1): 1 – 9.)
- [3] 朴明伟, 梁树林, 孔维刚, 等. 高速转向架非线性稳定性及安全裕度对策[J]. 振动与冲击, 2011, 30(8): 161 – 168.
(PIAO Mingwei, LIANG Shulin, KONG Weigang, et al. Non-linear stability of high-speed bogies and their safety margin strategy [J]. *Journal of Vibration and Shock*, 2011, 30(8): 161 – 168.)
- [4] 张学武, 吕艳云, 丁燕琼, 等. 小波统计法的表面缺陷检测方法[J]. 控制理论与应用, 2010, 27(10): 1331 – 1336.
(ZHANG Xuwu, LU Yanyun, DING Yanqiong, et al. Surface defect inspection based on wavelet statistical analysis [J]. *Control Theory & Applications*, 2010, 27(10): 1331 – 1336.)
- [5] ZHOU Y L, ZHAO P. Vibration fault diagnosis method of centrifugal pump based on EMD complexity feature and least square support vector machine [J]. *Energy Procedia*, 2012, 17, Part A(0): 939 – 945.
- [6] 张淑清, 孙国秀, 李亮, 等. 基于LMD近似熵和FCM聚类的机械故障诊断研究[J]. 仪器仪表学报, 2013, 34(3): 714 – 720.
(ZHANG Shuqing, SUN Guoxiu, LI Liang, et al. Study on mechanical fault diagnosis method based on LMD approximate entropy and fuzzy C-means clustering [J]. *Chinese Journal of Scientific Instrument*, 2013, 34(3): 714 – 720.)
- [7] ŽVOKELJ M, ZUPAN S, PREBIL I. Non-linear multivariate and multiscale monitoring and signal denoising strategy using Kernel Principal Component Analysis combined with Ensemble Empirical Mode Decomposition method [J]. *Mechanical Systems and Signal Processing*, 2011, 25(7): 2631 – 2653.
- [8] LEI Y, HE Z, ZI Y. EEMD method and WNN for fault diagnosis of locomotive roller bearings [J]. *Expert Systems with Applications*, 2011, 38(6): 7334 – 7341.
- [9] CHEN W T, WANG Z Z, XIE H B, et al. Characterization of surface EMG signal based on fuzzy entropy [J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2007, 15(2): 266 – 272.
- [10] 孙克辉, 贺少波, 尹林子, 等. 模糊熵算法在混沌序列复杂度分析中的应用[J]. 物理学报, 2012, 61(13): 71 – 77.
(SUN Kehui, HE Shaobo, YIN Linzi, et al. Application of FuzzyEn algorithm to the analysis of complexity of chaotic sequence [J]. *Acta Physica Sinica*, 2012, 61(13): 71 – 77.)
- [11] 陈小军, 李赞, 白宝明, 等. 一种基于模糊熵的混沌伪随机序列复杂度分析方法[J]. 电子与信息学报, 2011, 33(5): 1198 – 1203.
(CHEN Xiaojun, LI Zan, BAI Baoming, et al. A new complexity metric of chaotic pseudorandom sequences based on fuzzy entropy [J]. *Journal of Electronics & Information Technology*, 2011, 33(5): 1198 – 1203.)
- [12] 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.
- [13] AN X, JIANG D, LI S, et al. Application of the ensemble empirical mode decomposition and Hilbert transform to pedestal looseness study of direct-drive wind turbine [J]. *Energy*, 2011, 36(9): 5508 – 5520.
- [14] CHEN W, ZHUANG J, YU W, et al. Measuring complexity using FuzzyEn, ApEn, and SampEn [J]. *Medical Engineering & Physics*, 2009, 31(1): 61 – 68.
- [15] LIU C, LI K, ZHAO L, et al. Analysis of heart rate variability using fuzzy measure entropy [J]. *Computers in Biology and Medicine*, 2013, 43(2): 100 – 108.
- [16] 张家良, 曹建福, 高峰, 等. 结合非线性频谱与核主元分析的复杂系统故障诊断方法[J]. 控制理论与应用, 2012, 29(12): 1558 – 1564.
(ZHANG Jialiang, CAO Jianfu, GAO Feng, et al. Fault diagnosis of complex system based on nonlinear spectrum and kernel principal component analysis [J]. *Control Theory & Applications*, 2012, 29(12): 1558 – 1564.)

作者简介:

秦娜 (1978–), 女, 博士研究生, 研究方向为智能信息处理、模式识别, E-mail: qinna@home.swjtu.edu.cn;

金栋东 (1959–), 男, 教授, 博士生导师, 研究方向为智能信息处理、图像处理、模式识别, E-mail: wdjin@home.swjtu.edu.cn;

黄进 (1977–), 男, 副教授, 研究方向为图像处理、模式识别, E-mail: jhuang@home.swjtu.edu.cn;

李智敏 (1964–), 男, 工程师, 研究方向为智能信息处理、模式识别, E-mail: lizhimin@home.swjtu.edu.cn.