基于EEMD的高速列车横向减振器故障的排列熵特征分析

吴志丹 秦 娜 金炜东

(西南交通大学电气工程学院 成都 610031)

摘 要 针对高速列车转向架横向减振器状态监测数据的特点,提出了一种聚合经验模式分解和排列熵相结合的故障特征分析方法,用于在不同时间尺度下对信号进行复杂性分析。首先利用EEMD对横向减振器不同个数失效的7种工况信号进行分解,再用排列熵量化IMF的复杂度,得到多维特征向量集,最后采用支持向量机对故障状态进行分类识别。实验结果表明本方法对多个横向减振器失效的工况识别率最高可达100%,验证了排列熵特征对于高速列车横向减振器故障信号分析的有效性。

关键词 聚合经验模式分解,排列熵,横向减振器,高速列车,支持向量机

中图法分类号 TP391.4 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2016.5.058

Permutation Entropy Fault Feature Analysis Based on Ensemble Empirical Mode Decomposition for Lateral Damper of High-speed Train

WU Zhi-dan QIN Na JIN Wei-dong

(School of Electrical Engineering, Southwest Jiaotong University, Chengdu 610031, China)

Abstract To cope with the status monitoring data characteristics of high-speed train bogie's lateral damper, this paper proposed an analysis approach of fault characteristics combining EEMD and permutation entropy. The approach is used to do complexity analysis for signals under different time measure. Firstly, EEMD is used to decompose lateral damper's seven signal status with different number of invalid. Then, permutation entropy is used to measure IMF's complexity. Finally, support vector machine is used to classify the fault conditions. The experimental result shows that the recognition rate of multi-lateral dampers' fault can reach to 100% at most, proving the permutation entropy's effectiveness to signal fault analysis of high-speed train lateral damper.

Keywords Ensemble empirical mode decomposition, Permutation entropy, Lateral damper, High-speed train, Support vector machine

1 引言

横向减振器作为高速列车转向架的关键部件,对列车的安全运行品质和乘坐舒适度有着很大的影响。高速列车的一个车体上一般会安装4个横向减振器,前后转向架各安装两个;如果横向减振器少于4个,会大大降低列车的安全稳定性,尤其是前两个横向减振器或者后两个横向减振器同时失效时,其恶劣程度甚至要比4个横向减振器同时失效的情况要大[1]。信号处理与特征分析是进行高速列车转向架状态监测的重要步骤,但传统的信号分析方法在处理非平稳信号时具有一定的局限性。

聚合经验模态分解(Ensemble Empirical Mode Decomposition,EEMD)作为EMD算法的改进,在信号分解过程中加入了白噪声[2-4],不仅能保证自适应的分解特点,又能较好地抑制模式混叠,提高信号分解的准确度[5-7]。

排列熵作为一种新兴的描述非线性系统复杂度的算法,能将不易量化的系统复杂度和紊乱程度用简单的形式定量描述[8]。由于排列熵对信号的变化比较敏感,其已成功应用于医学领域[9]和机械振动信号的处理[10-12]等。

本文针对横向减振器故障的信号振动特点,提出EEMD和排列熵相结合的特征提取方法。将振动信号进行EEMD分解,根据相关系数选择出含有故障信号主要信息的IMF分量,提取其排列熵作为特征矢量,最后用于高速列车转向架的故障状态识别。基于EEMD排列熵的特征提取流程如图1所示。

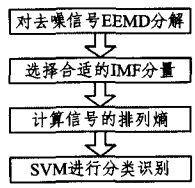

图1 基于EEMD排列熵的特征提取流程

到稿日期:2015-04-25 返修日期:2015-08-21 本文受国家自然科学基金重点项目(61134002),中央高校基本科研业务费专项资金(2682015CX025)资助。

吴志丹(1991-),女,硕士生,主要研究方向为模式识别、智能信息处理,E-mail:281348144@qq.com;秦 娜(1978-),女,博士,主要研究方向为模式识别、智能信息处理;金炜东(1959-),男,教授,博士生导师,主要研究方向为模式识别、图像处理与智能信息处理。

2 聚合经验模态分解

EEMD能根据信号本身的特点自适应地选择滤波频带和信号在不同频段内的分辨率。

EEMD的算法流程如下[13,14]：

(1)对聚合次数 N 和白噪声的幅值系数 k 进行初始化，设 $m=1$。

(2)在第 m 次信号中加入白噪声。

①如果在被分析的信号 $x(t)$ 中，根据给定的幅值添加白噪声序列，就可以得到带有白噪声的信号 $x_m(t)$。

$$x_m(t)=x(t)+kn_m(t) \tag{1}$$

式中，$n_m(t)$ 为 t 时刻第 m 次添加的白噪声序列。

②对加入白噪声后的信号 $x_m(t)$，利用经验模态分解方法分解得到若干个 IMFs。

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

(3)计算 N 次分解后的第 i 个 IMF 均值 $c_i(t)$：

$$c_i(t)=\frac{1}{N}\sum_{m=1}^{N}c_{i,m}(t) \tag{2}$$

式中，$c_{i,m}(t)$ 是第 m 次经验模态分解得到的第 i 个 IMF。

(4)取 M 个 IMF 的 N 次分解的均值作为最终的本征模态函数，则信号 $x(t)$ 可表示为：

$$x(t)=\sum_{i=1}^{M}c_i(t)+r(t) \tag{3}$$

式中，$r(t)$ 为具有单调性的残余函数。

3 排列熵

排列熵能用于分析信号的复杂性和不规律程度[10]，它以一种简单的方式将复杂的系统信号定量刻画出来。排列熵计算方便，计算值稳定，有很好的抗噪能力，对信号数据的微小变化也较为敏感，所以排列熵适用于各种时间序列。

对于时间序列 $\{x(i),i=1,2,\cdots,n\}$，通过进行相空间重构，可以得到信号的全部动态特性。根据延迟嵌入定理，得到重构的信号：

$$x(i)=[x(i)\quad x(i+\tau)\quad\cdots\quad x(i+(m-1)\tau)] \tag{4}$$

其中，τ 是时间延迟，m 是嵌入维数。信号重构后，使得 i 的最大值变为 $n-(m-1)\tau$，进而 $X(i)$ 向量的个数就变为 $k=n-(m-1)\tau$。将 $X(i)$ 里的元素按照升序进行重新排列，于是有：

$$x(i+(j_1-1)\tau)\leqslant x(i+(j_2-1)\tau)\leqslant\cdots\leqslant x(i+(j_m-1)\tau) \tag{5}$$

式中，$j_1,j_2,\cdots,j_m$ 表示 $X(i)$ 里各元素所处的位置。

如果 $X(i)$ 中出现两个元素相等的情况[15]，如：

$$x(i+(j_1-1)\tau)=x(i+(j_2-1)\tau) \tag{6}$$

按照 j 值的大小对 $X(i)$ 进行重新排列，即 $j_1\leqslant j_2$ 时，则：

$$x(i+(j_1-1)\tau)\leqslant x(i+(j_2-1)\tau) \tag{7}$$

因此，总是能在向量 $X(i)$ 中找到这种排列模式的序列：$S(l)=(j_1,j_2,\cdots,j_m)$。其中，$l=1,2,\cdots,k$ 且 $k\leqslant m!$，即向量的元素有 m 个，其排列方式最多可以有 $m!$ 种，$S(l)$ 只是这些排列方式中的一种。假设 $S(l)$ 这种排列方式出现的概率为：

$$p=num(S(l))/k \tag{8}$$

那么排列熵可表示为：

$$H_p(m,\tau)=-\sum_{l=1}^{k}p(l)\ln p(l) \tag{9}$$

H_p 越小，时间序列越规则，时间序列的复杂性越低；H_p 越大，时间序列越不规则，时间序列的复杂性越高[16]。

4 实验数据处理与分析

4.1 数据介绍

高速列车车体有两个转向架，每个转向架上装有两个横向减振器，本文所用数据为传感器收集的所有车体和构架的横向通道，主要对 4 个横向减振器的 7 种故障工况进行了模拟仿真实验，包括：(1)4 个横向减振器每一个单独失效，分别为：前左、前右、后左、后右；(2)两个转向架各一个横向减振器失效(交叉工况)；(3)前一个转向架两个横向减振器失效(前二工况)；(4)两个转向架 4 个横向减振器失效(全部工况)。

4.2 信号的经验模态分解

采用 EEMD 对预处理后的横向减振器的交叉工况、前二工况和全部工况进行分解，得到分解结果中前 8 个 IMFS 分量和 1 个余项，且按照频率的高低依次分布。对各个单分量进行研究，可以获取信号的局部特性。由于通过 EEMD 分解会得到一些虚假分量，这些分量会对后续的特征提取造成影响，因此选择有效分量作为分析对象。通过计算各个分量与原信号的互相关系数来选择合适的 IMF 分量，3 种工况的相关系数结果见表 1。

表 1 3 种工况的 IMF 分量的相关系数

工况类型	IMF1	IMF2	IMF3	IMF4	IMF5	IMF6	IMF7	IMF8
交叉工况	0.0093	0.0306	0.0840	0.1700	0.5593	0.9398	0.4673	0.1255
前二工况	0.0336	0.0910	0.3010	0.3711	0.5250	0.7136	0.6527	0.3023
全部工况	0.0099	0.0395	0.0988	0.2024	0.9899	0.6456	0.5104	0.1481

从表 1 可以看出，3 种工况的 IMF5、IMF6 和 IMF7 这 3 个分量的互相关系数要比其它几个分量的大，它们包含了原信号的大部分信息，故选择 IMF5、IMF6 和 IMF7 这 3 个分量作为特征分量。通过提取这 3 个分量的复杂度特征，构成三维向量特征集，以此来表征原信号的局部特性。

4.3 排列熵特征提取

排列熵的计算中，参数的选择对熵值的计算结果会产生一定的影响。重构空间维数 m 的值越大，越能体现信号动态演化的过程。由互信息法和伪近邻法得到时间延迟，嵌入维数 $m=4$。

对横向减振器的交叉工况、前二工况和全部工况的仿真数据各截取了 100 个样本，以 500 个样本点为一个样本，运行速度为 200km/h。提取 3 种工况的 IMF5、IMF6、IMF7 分量的排列熵，构成三维特征向量集。图 2－图 4 分别是横向减振器的 3 种工况在不同通道下的排列熵值空间分布。

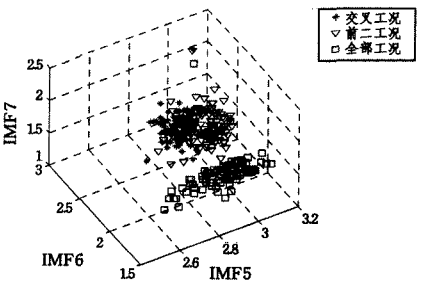

图 2 车体前部排列熵值空间分布

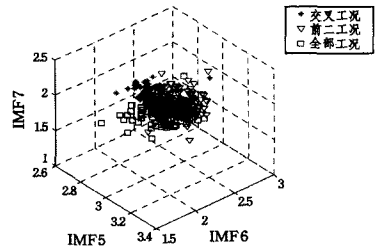

图 3　构架一架一位排列熵值空间分布

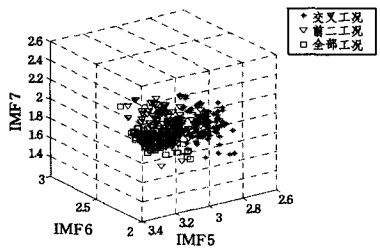

图 4　构架一架中部排列熵值空间分布

从图 2—图 4 可以看出，交叉工况、前二工况和全部工况的样本在三维空间中展现了很好的类内聚集性和类间分离性，说明排列熵作为特征可以对 3 种工况进行识别，而且具有很好的稳定性和抗噪性。

排列熵所表示的意义是值越小则信号越规律，值越大则信号越复杂。前转向架两个横向减振器失效工况的排列熵最小，对列车的振动影响最大；其次是 4 个横向减振器全失效工况，影响最小的是前后转向架各一个横向减振器失效工况。文献[1,17]中对此都有说明，当横向减振器前两个失效时，列车振动的恶化程度甚至要比 4 个减振器全部失效的情况大。其主要原因在于前部构架的横向减振器全失效，而后部构架的横向减振器全正常，会导致列车结构产生不对称，从而产生横向非线性振动，与本文所得出的结论相符。

取横向减振器单个失效的 4 种工况振动数据作为测试信号，各截取了 100 个样本，以 500 个样本点为一个样本，运行速度为 200km/h。提取 4 种工况的 IMF5、IMF6、IMF7 分量的排列熵，构成三维特征向量集，以位于车体和构架上传感器采集的数据为例，4 种单一工况的排列熵的空间分布如图 5 和图 6 所示。

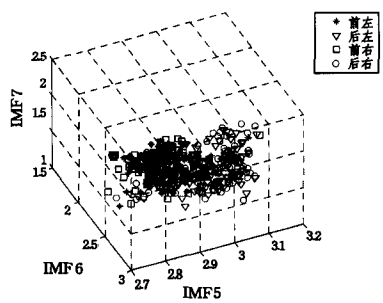

图 5　车体前部排列熵值空间分布

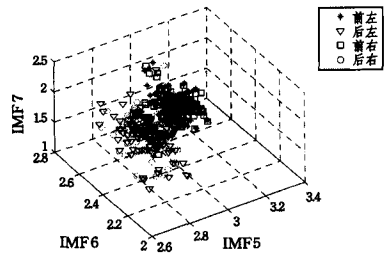

图 6　构架二架二位排列熵值空间分布

对于横向减振器单个失效的 4 种工况而言，可从图 5 和图 6 的排列熵空间分布中看出，横向减振器前左失效和前右失效的特征集混叠在一起，横向减振器后左失效和后右失效的特征集混叠在一起，而前左失效和前右失效的特征集与后左失效和后右失效的特征集在空间上能明显地区分，说明同一构架上的横向减振器失效时，排列熵值的大小较接近；而不同构架上的横向减振器失效时，排列熵值不同。同一构架上两个横向减振器的位置安装比较接近，任何一个失效对列车振动的影响差异不大；而不同构架的横向减振器失效所引起的振动是有差异的，根据图中排列熵的大小可知，前部单个横向减振器失效对车体前部的影响大于后部单个横向减振器失效的情况，后部单个横向减振器失效对车体后部的影响大于前部横向减振器单个失效的情况。

利用支持向量机对横向减振器 7 种工况进行分类识别。为了验证本文方法的有效性，数据实验采用 3 种方法进行对比，其结果如表 2 所列。

表 2　3 种特征提取方法的分类识别率

通道	特征提取方法	交叉工况	前二工况	全部工况	单个工况（平均）
车体前部	EMD+排列熵	60%	74%	60%	14%
	EEMD+样本熵	68%	82%	82%	20%
	EEMD+排列熵	84%	90%	100%	45%
一架中部	EMD+排列熵	66%	82%	66%	24%
	EEMD+样本熵	74%	70%	64%	18%
	EEMD+排列熵	86%	100%	100%	48%

通过分析表 2 可知，在针对高速列车转向架横向减振器故障信号的特征提取中，EEMD 分解结合排列熵方法比传统方法具有更好的识别效果。本方法对多个横向减振器失效的工况的识别率最高可达 100%，对于横向减振器多个失效的工况的检测有很高的可行性；但对单个横向减振器失效的识别率却略低，这是因为同一构架上的两个横向减振器分别失效时，对列车的振动影响情况接近，导致难以区别同一构架上两个横向减振器失效的具体位置，但如果将同一构架上的两个横向减振器归为一类，它的识别率可以达到 100%。因此将 EEMD 排列熵作为特征，可以识别出是前部构架上的横向减振器发生故障还是后部构架上的横向减振器发生了故障，这对于在实际中的检测具有重要的意义。

结束语　本文提出了基于聚合经验模态分解和排列熵的振动信号特征提取方法，利用 EEMD 自适应地将信号分解成一系列频率成分不同的 IMF 分量，各个分量都包含了信号的不同局部特性。以互相关系数为依据，选择了合适的 IMF 分量进行排列熵计算并构建了三维特征向量集，实现了以局部复杂度为判断依据的特征提取方法。排列熵作为识别多个横向减振器失效的特征时，不仅能够对 3 种工况很好地识别，而且还能判断出各种工况对列车运行的危害程度。在实际运行中，为保证高速列车具有良好的运行平稳性与安全性，应尽量避免同一构架上横向减振器全部失效的情况出现。

参 考 文 献

[1]　Liu Jian-xin, Wang Kai-yun, Feng Quan-bao, et al. Influence of lateral damper on locomotive riding quality[J]. Journal of Traffic and Transportation Engineering, 2006, 6(3): 1-4(in Chinese)
刘建新，王开云，封全保，等. 横向减振器对机车平稳性能的影响[J]. 交通运输工程学报，2006，6(3)：1-4

[2]　Qin Na, Wang Kai-yun, Jin Wei-dong, et al. Fault feature analy-

sis of high-speed train bogie based on empirical mode decomposition entropy[J]. Journal of Traffic and Transportation Engineering,2014,14(1):57-64(in Chinese)
秦娜,王开云,金炜东,等.高速列车转向架故障的经验模态熵特征分析[J].交通运输工程学报,2014,14(1):57-64

[3] Wu Z H,Huang N E. Ensemble empirical mode decomposition:a noise-assisted data analysis method[R]. Calverton:Center for Ocean-Land-Atmosphere Studies,2009

[4] Wu Z H,Huang N E. A study of characteristics of white noise using the empirical mode decomposition method[C]// Proceedings of the Royal Society,Series A:Mathematical,Physical and Engineering Science. London:The Royal society,2004:1597-1611

[5] Yeh J A,Shieh J S,Huang N E. Complementary ensemble enpicical mode decomposition:a novel noise enhanced data analysis method[J]. Advances in Adaptive Data Analysis,2010,2(2):135-156

[6] Hong H,Zhu X H,Su W M. Detection of time varying pitch in tonal languages:an approach based on ensemble empirical mode decomposition[J]. Zhejiang Univ-Sic C,2012,13(2):139-145

[7] Qin Na,Jin Wei-dong,Huang Jin,et al. Feature extraction of high speed train bogie based on ensemble empirical mode decomposition and sample entropy[J]. Journal of Southwest Jiaotong University,2014,49(1):27-32(in Chinese)
秦娜,金炜东,黄进,等.基于 EEMD 样本熵的高速列车转向架故障特征提取[J].西南交通大学学报,2014,49(1):27-32

[8] Bandt C,Pompe B. Permutation entropy:a natural complexity measure for time series[J]. Physical Review Letters,2002,88(17):174102

[9] Zhao Xiao-lei,Ren Ming-rong,Zhang Ya-ting,et al. Nonlinear analysis of ECG signal based on permutation entropy[J]. Modern Electronic Technology,2010,33(19):90-92(in Chinese)
赵小磊,任明荣,张亚庭,等.基于排列熵的心电信号非线性分析[J].现代电子技术,2010,33(19):90-92

[10] Sun Ke-hui,Tan Guo-qiang,Sheng Li-yuan. Analysis of chaotic pseudo-random sequence complexity based on permutation entropy[J]. Computer Engineering and Applications,2008,44(3):47-49(in Chinese)
孙克辉,谈国强,盛利元.基于排列熵算法的混沌伪随机序列复杂性分析[J].计算机工程与应用,2008,44(3):47-49

[11] Feng Fu-zhou,Si Ai-wei,Jiang Peng-cheng. Application in fault prediction of related permutation entropy of wavelet and HMM[J]. Journal of Vibration Engineering,2013,26(2):269-276(in Chinese)
冯辅周,司爱威,江鹏程.小波相关排列熵和 HMM 在故障预测中的应用[J].振动工程学报,2013,26(2):269-276

[12] Feng Fu-zhou,Rao Guo-qiang,Si Ai-wei,et al. Entropy permutation algorithm and its application in the vibration signal detection of mutations[J]. Journal of Vibration Engineering,2012,25(2):221-224(in Chinese)
冯辅周,饶国强,司爱威,等.排列熵算法研究及其在振动信号突变检测中的应用[J].振动工程学报,2012,25(2):221-224

[13] He Hui-yan,Sun Yun-qiang,Li Xiao-feng,et al. Frequency analysis of the penetration acceleration signal based on EEMD and Choi-Willians distribution[J]. Journal of North University of China(Natural Science),2012,33(5):547-567(in Chinese)
郝慧艳,孙运强,李晓峰,等.基于 EEMD 和 Choi-Willians 分布的侵彻加速度信号时频分析[J].中北大学学报(自然科学版),2012,33(5):547-567

[14] Liu Yi-yan,He Shuan-hai,Ju Yong-feng,et al. Trend prediction for a single-degree of freedom structure's state based on EEMD and SVR[J]. Journal of Vibration and Shock,2012,31(5):60-64(in Chinese)
刘义艳,贺栓海,巨永锋,等.基于 EEMD 和 SVR 的单自由度结构状态趋势预测[J].振动与冲击,2012,31(5):60-64

[15] Yang J,Zhang Y,Zhu Y. Intelligent fault diagnosis of rolling element bearing based on SVMs and fractal dimension[J]. Mechanical Systems and Signal Processing,2007,21(5):2012-2024

[16] Liu Yong-bin. Nonlinear signal analysis for rolling bearing condition monitoring and fault diagnosis[D]. Hefei:University of Science and Technology of China,2011(in Chinese)
刘永斌.基于非线性信号分析的滚动轴承状态监测诊断研究[D].合肥:中国科学技术大学,2011

[17] Huang Yun-hua,Li Fu,Fu Mao-hai,et al. Influence of lateral damper place model over metro vehicle on dynamics performance[J]. Urban Mass Transit,2010,13(8):39-42(in Chinese)
黄运华,李芾,付茂海,等.横向减振器布置方式对地铁车辆动力学性能的影响[J].城市轨道交通研究,2010,13(8):39-42

(上接第 278 页)

[8] Zhang J,Wei Z H. A class of fractional-order multi-scale variational models and alternating projection algorithm for image denoising [J]. Applied Mathematical Modelling,2011,35(5):2516-2528

[9] Jiang Wei. Fractional denoising new model based on PDE[J]. Computer Applications,2011,31(3):753-756(in Chinese)
蒋伟.基于分数阶偏微分方程的图像去噪新模型[J].计算机应用,2011,31(3):753-756

[10] Tian Dan,Xue Ding-yu,Yang ya-jie. Fractional original dual denoising model and the numerical algorithm noising[J]. China Image and Graphics,2014,19(6):852-858(in Chinese)
田丹,薛定宇,杨雅婕.分数阶原始对偶去噪模型及其数值算法[J].中国图象图形学报,2014,19(6):852-858

[11] Combettes P L,Wajs V R. Signal recovery by proximal forward-backward splitting[J]. Multiscale Modelin & Simulation,2005,4(4):1168-1200

[12] Purkait P,Chanda B. Super resolution image reconstruction through bregman iteration using morphologic regularization[J]. IEEE Transactions on Image Processing,2012,21(9):4029-4039

[13] Afonso M V,Bioucas-Dias J M,Figueiredo M A T. Fast image recovery using variable splitting and constrained optimization [J]. IEEE Transactions on Image Processing,2010,19(9):2345-2356

[14] Mourad N,Reilly J P. Automatic threshold estimation for iterative shrinkage algorithms used with compressed sensing[C]// 2012 IEEE International Conference on Kyoto:Acoustics,Speech and Signal Processing(ICASSP). 2012:2721-2794

[15] Xu Y,Yin W,Osher S. Learning circulant sensing kernels[J]. Inverse Problems and Imaging,2014,8(3):901-923

[16] Bioucas-Dias J M,Figueiredo M A T. A New TwIST:Two-step iterative shrinkage/thresholding algorithms for image restoration[J]. IEEE Transactions on Image Processing,2007,16(12):2992-3004