基于EMD及PNN的航天器振动环境分析

杨 海 程 伟

(北京航空航天大学 航空科学与工程学院，北京 100191)

摘 要：针对航天器非平稳随机振动信号模态频率密集的特点，提出了基于经验模式分解EMD (Empirical Mode Decomposition)的多分量过程神经网络PNN(Process Neural Network)自回归模型.通过EMD对原始时间序列进行分解，使之成为一组不同尺度的局部正交本征模函数IMF(Intrinsic Mode Functions)，利用PNN对每个IMF分别进行时变参数分析并以此确定其时变自功率谱密度，对所有分量的时变自功率谱密度通过叠加进行重构，以此得到原始信号的时变自功率谱密度.仿真结果和实例分析表明：和传统的时频分析法相比，该方法直接使用信号数据，避免了相关估计计算，减小了计算工作量；无交叉干扰项，提高了信号的时频分布特性，具有较高的时频分辨率；对各工况下航天器的振动信号能有效的进行分析，具有较强的信号特征提取能力.

关 键 词：非平稳随机振动信号；时变参数模型；功率谱；过程神经网络(PNN)；经验模式分解(EMD)

中图分类号：V 217

文献标识码：A **文 章 编 号**：1001-5965(2008)06-0622-05

Environmental analysis based on PNN and EMD for vibration of spacecraft

Yang Hai Cheng Wei

(School of Aeronautic Science and Engineering, Beijing University of Aeronautics and Astronautics, Beijing 100191, China)

Abstract: In view of the disadvantages of the traditional time-varying parameters modeling algorithm about nonstationary random vibration signal of a spacecraft with closed spaced modal frequency, a multicomponent process neural network (PNN) autoregressive model was proposed, which was based on the empirical mode decomposition (EMD). The EMD was utilized to decompose the original time series into several local orthogonal intrinsic mode functions (IMF) with different time scale. The PNN was established for anyone of these IMF, and obtained time-varying power spectrum density (PSD). The time-varying PSD of the original signal was reconstituted by superposing. The simulation and example analyzed results suggest that this method avoids the correlative estimation calculation and reduces the calculation complexity. There is no cross-term interference, so it improves the time-frequency distributing characteristic of the signals. This method has a higher ability of extracting signal characteristic and can be used to analyze the vibration signals of spacecraft under various work conditions.

Key words: nonstationary random vibration signal; time-varying parameter model system; power spectrum; process neural network(PNN); empirical mode decomposition(EMD)

传统的功率谱分析法假定信号是平稳的，而 航天器在飞行过程中经历的振动环境是非平稳

收稿日期：2007-05-31

基金项目：航空科学基金资助项目(20071551016)

作者简介：杨 海(1976—)，男，四川成都人，博士生，yanghai@ase.buaa.edu.en.

的,对这类振动环境的处理,应采用时频分析,如短时傅里叶变换、Wigner-Ville 分布、小波变换等[1].这些方法在不同程度上对非平稳信号的时变性给予了恰当的描述,改进了传统方法的不足,但也暴露出某些局限性.文献[2]提出的 HHT(Hilbert-Huang Transform)在分析非平稳数据方面有所突破,其核心在于用 EMD(Empirical Mode Decomposition)的方法把复杂数据自适应地分解成有明确物理意义的有限个 IMF(Intrinsic Mode Functions).与小波分析方法相比,这是一种无需任何先验知识的自适应时频分析方法.其基函数只依赖于信号本身,且数据的分解有明确的物理意义.HHT 虽然提出时间不长,其理论和应用已得到广泛的关注与研究[3].

航天器在飞行过程中采集到的非平稳信号通常模态频率密集、信噪比低、波形复杂.若直接对信号进行 EMD 分解不能得到标准的 IMF(任意时刻只有唯一的瞬时频率),而是得到一个包含多个单分量信号的 IMF.对这种 IMF 再进行 Hilbert 分析,得到的时频分布会与实际情况不一致.针对上述问题,采用 PNN(Process Neural Network)对航天器实测振动数据的非标准 IMF 进行时变参数分析.

1　数学模型构造算法

EMD 假设信号是由若干个 IMF 组成的,且 IMF 必须满足如下两个准则:过零点数与极点数相等或相差 1;在数据中的任意一点,由局部极大值确定的包络线和局部极小值确定的包络线得到的均值为零.EMD 方法的主要过程如下:

1) 找出信号 $s(t)$的全部极大和极小值点,利用三次样条函数分别把它们拟合为该信号的上下包络线,计算出两包络线的均值 $m(t)$,进而求出 $s(t)$与 $m(t)$的差 $h(t)$.

2) 若 $h(t)$不满足 IMF 的要求,则重复上述筛选过程,直至新的 $h(t)$满足 IMF 的准则;若 $h(t)$满足 IMF 的要求,令其为原信号的一个 IMF,并求出 $s(t)$与该 $h(t)$的差值 $r(t)$.

3) 将 $r(t)$作为待分解信号,重复以上过程,直至所剩余的 $r(t)$不可分解或其研究意义已经不大为止.至此,信号 $s(t)$分解为

$$s(t)=\sum_{i=1}^{n}C_i(t)+r_n \tag{1}$$

式中,$C_i(t)$为各个 IMF 分量,各 IMF 按瞬时频率由高到低分解得到;r_n 为残余项.

EMD 本身证明了它具有完备性,文献[2]指出,EMD 的正交性在所有实际意义上都是满足的,通过分解得到的所有模式分量都应在局部正交,因为每一个 IMF 都是从原始信号与由极大值包络和极小值包络得到局部均值的差值得到的.

在实际分析过程中,不可能严格按照 IMF 的定义去分解,因此需要一个判据判断其合理性,现在普遍采用的判据为前后两个 $h(t)$的标准差:

$$s_{\mathrm{d}}=\sum_{t=0}^{T}\left(\frac{h_{i(k-1)}(t)-h_{i(k)}(t)}{h_{i(k-1)}(t)}\right)^2 \tag{2}$$

式中,下标 i 为当前分析的是第 i 阶 IMF 分量;k 为重复的次数;T 为离散信号序列的总时间长度.通常 s_{d} 取为 0.2～0.3.

对于复杂信号中非常靠近的频率成分,由于 s_{d} 的取值在很大程度上取决于经验,使得分解出的 IMF 分量与信号实际的构成分量之间存在一定的误差,导致 EMD 不易将其分解为相互独立的 IMF 分量.若对这种 IMF 再进行 Hilbert 谱分析,得到的时频分布会与实际情况不一致.对此,短时傅里叶变换在兼顾时间分辨率的情况下也无能为力,而小波变换在选择合适的分解尺度时虽能将其分开,但同时得到的无用谐波也更多.为了降低 EMD 分解误差的影响,建立一个 PNN 网络对 IMF 进行时变参数分析.PNN 的输入和连接权函数均可为一个时变过程,并在传统神经元空间聚合运算的基础上,增加一个时间聚合算子,使过程神经元的聚合运算和激励作用能同时反映输入信号的空间和时间效应[4-5].

设 PNN 的输入为 $\boldsymbol{x}(t)$,输出为 $\boldsymbol{y}(t)$,其中 $\boldsymbol{x}(t),\boldsymbol{y}(t)\in C[0,T]$.考虑一个 4 层结构的 PNN 模型:输入层有 n 个节点,用于完成 $\boldsymbol{x}(t)$的输入;第 1 隐层为过程神经元隐层,由 m 个节点组成,完成对 $\boldsymbol{x}(t)$在空间上的加权聚合和时间过程的聚合运算;第 2 隐层为非时变一般神经元,有 L 个节点,完成第 1 隐层输出的空间加权聚合运算;最后为输出层,完成网络的输出.网络的拓扑结构如图 1 所示.

根据图 1 所示可知第 1 隐层的输出为

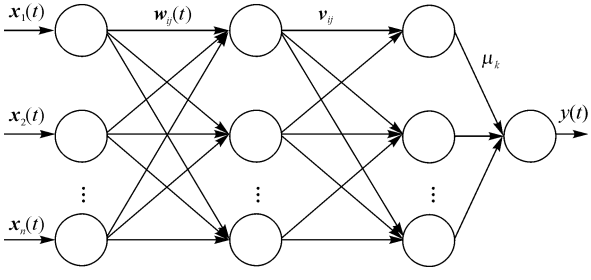


图 1　4 层过程神经网络拓扑结构

$$y_j^1 = f\left(\sum_{i=1}^{n}\int_0^t \omega_{ij}(\tau)x_i(t)\mathrm{d}\tau - \theta_j^1\right) \tag{3}$$

式中，y_j^1 为第1隐层第 j 个过程神经元的输出；$\omega_{ij}(t)$ 为输入层与第1隐层的时变连接权函数；θ_j^1 为第1隐层第 j 个过程神经元的输出阈值；$t\in[0,T]$ 为采样时间；f 为第1隐层的激励函数.

根据第1隐层的输出，可得第2隐层的输出为

$$y_l^2 = g\left(\sum_{j=1}^{m} v_{jl}y_j^1 - \theta_l^2\right) \tag{4}$$

式中，y_l^2 为第2隐层第 l 个神经元的输出；v_{jl} 为第1隐层第 j 个过程神经元与第2隐层第 l 个神经元的连接权函数；θ_l^2 为第2隐层第 l 个神经元的输出阈值；g 为第2隐层的激励函数.

根据第2隐层的输出可得网络的输出为

$$y(t) = h\left(\sum_{l=1}^{L}\mu_l g\left(\sum_{j=1}^{m} v_{jl} f\cdot\left(\sum_{i=1}^{n}\int_0^t \omega_{ij}(\tau)x_i(t)\mathrm{d}\tau - \theta_j^1\right) - \theta_l^2\right) - \theta^3\right) \tag{5}$$

式中，$y(t)$ 为神经网络的输出；μ_l 为输出层与第2隐层第 l 个神经元的连接权函数；θ^3 为输出层神经元的输出阈值；h 为输出层的激励函数. 当网络各层的激励函数为线性传递函数、输出阈值为0时，将 $\omega_{ij}(t)$ 表示为基函数展开的形式：

$$\omega_{ij}(\tau) = \sum_{r=1}^{R}\omega_{ij}^r b_r(\tau) \tag{6}$$

式中，ω_{ij}^r 为相对于 $b_r(\tau)$ 的输入层与第1隐层的连接权. 将其代入式(5)可得

$$y(t) = \sum_{l=1}^{L}\mu_l\sum_{j=1}^{m}v_{jl}\sum_{i=1}^{n}\int_0^t\sum_{r=1}^{R}\omega_{ij}^r b_r(\tau)x_i(t)\mathrm{d}\tau \tag{7}$$

令 $$a_i(t) = -\sum_{l=1}^{L}\sum_{j=1}^{m}\mu_l v_{jl}\int_0^t\sum_{r=1}^{R}\omega_{ij}^r b_r(\tau)\mathrm{d}\tau$$

则 $$y(t) = -\sum_{i=1}^{n}a_i(t)x_i(t) \tag{8}$$

若系统真实输出为 $\hat{y}(t)$，误差为 $\varepsilon(t)$，则

$$\hat{y}(t) = y(t) + \varepsilon(t) = -\sum_{i=1}^{n}a_i(t)x_i(t) + \varepsilon(t) \tag{9}$$

式(9)为一个 n 阶时变 AR(Autoregressive)模型，由此可知只要将待建立时变参数模型的输入信号作为训练样本，投射到以时变权函数基展开的神经网络进行训练，即可用网络稳定后所得的权重来计算其时变 AR 模型的参数. 类似平稳情况，时变 AR 参数模型谱可用 Wold-Crammer 进化谱来定义[6]. 根据 AR 模型传递函数和已知输入白噪声的功率可得出该非平稳信号的时变功率谱：

$$s(f,t) = \frac{\Delta t\sigma^2(t)}{\left|1 + \sum_{i=1}^{n}a_i(t)\exp(-j2\pi\mathrm{i}f\Delta t)\right|^2} \tag{10}$$

式中，$\sigma(t)$ 为时变 AR 模型激励白噪声 $W(t)$ 的平均功率，由于 $W(t)$ 是神经网络的误差 $\varepsilon(t)$ 的输出，即 $W(t)=\varepsilon(t)$，由此可以估计 $\sigma(t)$.

一般来说，模型的阶次预先是不知道的. 对非平稳随机信号模型阶次的确定，目前还没有很成熟的方法. 文献[7]分析了 AIC 准则应用的充分条件，并基于这些充分条件，研究 AIC 准则在非平稳随机信号模型阶次的确定方面的应用问题，得出这些问题和参数估计及它们的渐进常态是一致的. 因此对时变模型的定阶拟采用 AIC 准则.

2 仿真计算

3个非线性调幅信号的叠加方程为

$$z = (1+t+t^2)(\sin 80\pi t + \sin 44\pi t + \sin 40\pi t) \tag{11}$$

在3个非线性调幅信号中有两个信号的频率非常接近. 对该信号采样(采样率为 100 Hz，采样长度为 512)后用 EMD 进行分解得到图 2. 从图 2 可以看出仿真信号经 EMD 分解后得到三阶 IMF 和残余项，分别记为 IMF1，IMF2，IMF3 及残余项. 其中 IMF1 是标准的 IMF 分量，只含有一个单分量信号，它对应 40 Hz 的非线性调幅分量；IMF2 是典型的非标准 IMF 分量，为由两个频率很接近的单频信号形成的拍频信号. 由于 IMF2 不满足 Hilbert 谱分析对 IMF 的要求，即任意时刻只有一个瞬时频率. 为了克服上述错误，运用 PNN 自回归模型，根据 AIC 准则选取时变 AR 模型为六阶，神经网络结构中的隐层单元总数可

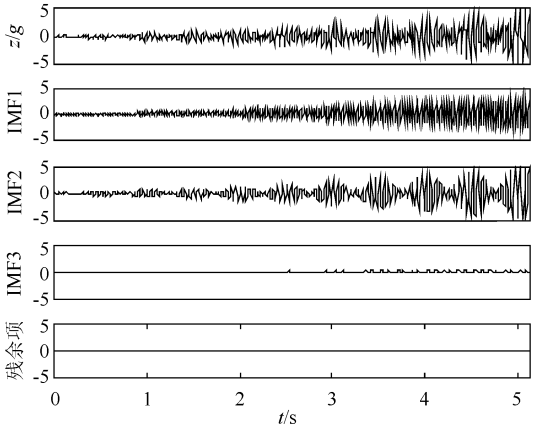


图2 仿真信号、各阶 IMF 及残余项

以按照由 AR 模型的阶次 p 的两倍来确定[8](时间基函数选用三阶勒让德基)对每个 IMF 分别进行时变参数分析,并以此确定 IMF 的时变自功率谱密度,然后根据各分量的局部正交性对所有分量的时变自功率谱密度通过叠加进行重构,得到如图 3 所示的时变自功率谱密度. 图 3 较为准确地描述了仿真信号能量的时频分布,从图 3 中可明显看出在 20,22 和 40 Hz 处有 3 个信号分布,20 和 22 Hz 的信号能量的幅值基本相同且大小相当于 40 Hz 处信号能量的一半.

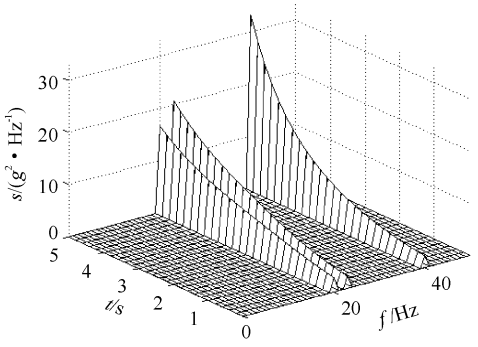


图 3　仿真信号的 PNN 时频谱

3　实例应用

对某型航天器飞行过程中采集到振动信号,采用 EMD 方法进行分解,共得到十三阶 IMF 分量和一个残余项,这里只列出了前三阶 IMF 分量和残余项如图 4 所示. 从图 4 中可以看出,各阶

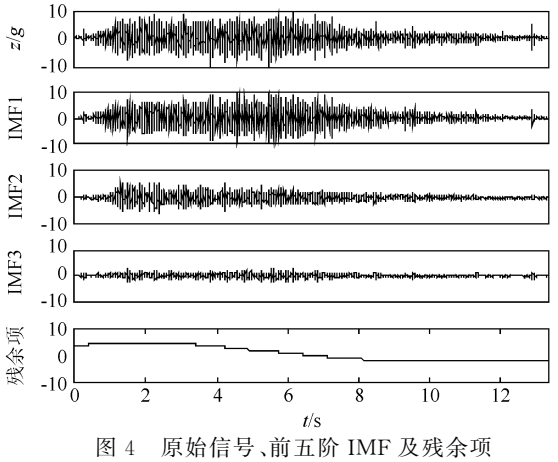


图 4　原始信号、前五阶 IMF 及残余项

IMF 分量包含了不同的时间尺度,使得信号的特征在不同的分辨率下显露出来. 同时,从图 4 中还可以看出,EMD 也是一种主成分提取法,分解结果中前面的几个 IMF 分量包含了原始信号的主要信息. 但是分解出的 IMF 并非全是只包含一个单分量信号的标准 IMF,而是含有多个单分量信号的非标准 IMF. 这种情况在前二阶 IMF 分量中表现的特别明显. 对前二阶 IMF 分量,运用二十阶 PNN 自回归模型(时间基函数选用三阶勒让德基)进行时变参数分析,得到各阶 IMF 分量的时变自功率谱密度如图 5 和 6 所示. 从图中可以看出,振动信号的能量主要集中在 230 到 260 Hz 的频段. 此频段信号的能量随时间动态变化的趋势得到了比较清晰的显示. 可见该频段振动信号与激励信号有很强的相关性,根据振动力学系统响应和激励的关系可知,系统的激励信号能量也主要集中在该频段,动态变化也和振动响应信号一致. 而 130 Hz 处的信号,在初始阶段有较强的能量显示,但随着时间的推移能量减少. 由此可知该信号可能是一个干扰信号.

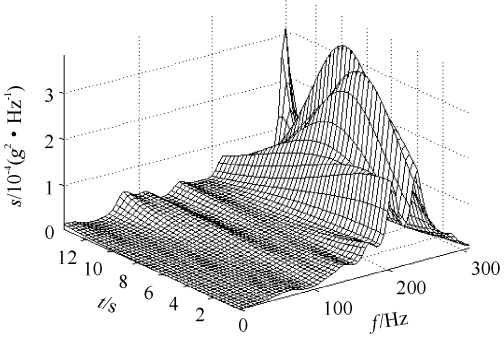


图 5　一阶 IMF 的 PNN 时频谱

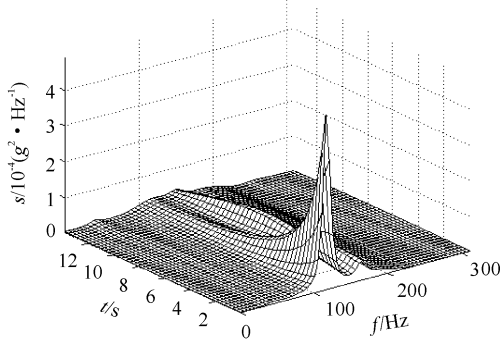


图 6　二阶 IMF 的 PNN 时频谱

根据 IMF 分量的局部正交性,对前三阶 IMF 分量的时变自功率谱密度通过叠加进行重构,得到如图 7 所示的时变自功率谱密度. 将其与分段短时傅里叶变换所得功率谱图 8 进行比较. 可以看出,两者都描述了信号的时频特性,信号能量随

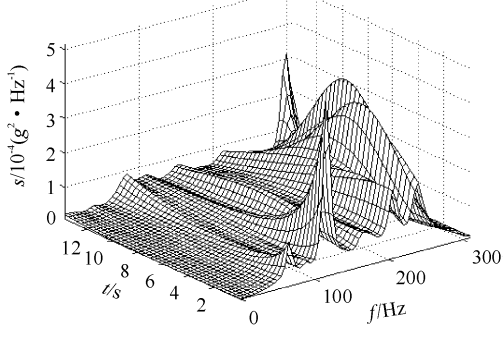


图 7　前三阶 IMF 叠加的 PNN 时频谱

时间变化的规律基本一致.但是图8中存在较大干扰项,以及较大的噪音能量分布,低频部分的信号不明显,而且谱分辨率明显不如图7.由此表明利用PNN估计时变AR模型参数和时变功率谱的方法是有效的.该方法直接使用信号数据,避免了相关估计计算,因而减小了计算工作量,提高了计算精度.它可根据实际情况调整PNN神经网络的隐层数和神经单元数,使得可以利用较少的内存对数据量很大的信号进行分析.

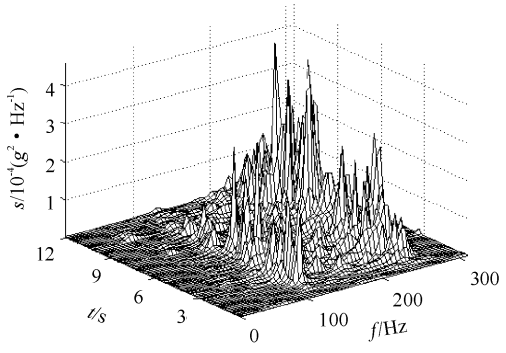


图8 短时傅里叶变换功率谱

4 结束语

通过仿真,对于多个频率接近的非线性调幅信号叠加的情况,用基于经验模态分解方法的多分量过程神经元网络对信号进行分析,取得了较好的效果,该方法有效地避免了把包含多个单分量信号的*IMF*近似为单分量信号所带来的问题,提高了频率分辨率,减少了随机误差.

参考文献(References)

[1] 胡广书.数字信号处理:理论、算法与实现[M].第2版.北京:清华大学出版社,2003:26-28
Hu Guangshu. Digital signal processing: theory, method and realizing[M]. Second Edition. Beijig: Tsinghua University Press, 2003: 26-28 (in Chinese)

[2] Huang N E, Shen Z, Long S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and nonstation time-series analysis [J]. Proc R Soc, 1998, A454: 903-995

[3] 钟佑明,秦树人,汤宝平.一种振动信号新变换法的研究[J].振动工程学报,2002,15(2):233-238
Zhong Youming, Qin Shuren, Tang Baoping. Study on a new transform method for vibration signal [J]. Journal of Vibration Engineering, 2002,15(2):233-238(in Chinese)

[4] 许少华,何新贵,刘坤,等.关于连续过程神经元网络的一些理论问题[J].电子学报,2006,34(10):1838-1841
Xu Shaohua, He Xingui, Liu Kun, et al. Some theoretical issue on continuous process neural networks[J]. Acta Electronica Sinica, 2006,34(10):1838-1841(in Chinese)

[5] 许少华,何新贵.径向基过程神经元网络及其应用研究[J].北京航空航天大学学报,2004,30(1):14-17
Xu Shaohua, He Xingui. Research and applications of radial basis process neural network [J]. Journal of Beijing University of Aeronautics and Astronautics, 2004,30(1):14-17 (in Chinese)

[6] Kayhan A S, Jaroudi A, Chaparral L F. Data adaptive evolutionary spectral estimation [J]. IEEE Trans on Signal Processing, 1995,43 (1):204-213

[7] Konzin F, Nakajima F. The order determination problem for linear time-varying AR models [J]. IEEE Trans on Automatic Contral, 1980,25 (2):250-257

[8] 杨基海,陈香.利用神经网络估计针电极肌电信号的AR模型参数和功率谱[J].北京生物医学工程,2000,19(2):174-179
Yang Jihai, Chen Xiang. Estimation of the coefficients of the AR model and PDS of NEMG signal using ANN[J]. Beijing Biomedical Engineering, 2000,19(2):174-179(in Chinese)

(责任编辑:刘登敏)