

# 基于经验模态分解与RBF神经网络的混合预测\*

李方溪, 陈桂明, 朱露, 刘希亮, 李胜朝

(第二炮兵工程大学五系 西安, 710025)

**摘要** 为提高时间序列预测模型精度,根据各本征模态函数(intrinsic mode function,简称IMF)序列的变化特点,针对EMD-RBF神经网络隐含神经元数目及其中心数据选取问题,利用经验模态分解(empirical mode decomposition,简称EMD)的信号自适应处理能力和径向基函数(radical basis function,简称RBF)神经网络的非线性逼近能力,提出了一种基于EMD与RBF神经网络的混合预测方法。该方法将具有类似时频特性的本征模态函数分别建立RBF神经网络预测模型,采用基于统计分析的k-均值聚类方法自适应确定RBF模型参数,最后将各IMF-RBF神经网络预测结果进行重构得到最终预测结果。仿真结果表明,该方法充分考虑到各IMF本身的特性,增强了时序的可预测性,预测性能比传统反向传播(back propagation,简称BP)神经网络和小波BP神经网络更优越。将该方法应用在某装备温控系统性能监测中,其温度参数最大预测误差远小于传感器误差,说明将该方法在该装备故障预测中是可行的。

**关键词** 经验模态分解; 径向基函数神经网络; 预测; 模态混叠

**中图分类号** TP274; TH17; TJ07

## 引言

故障预测是通过建立准确的预测模型来表征系统的内在特征,预知系统将来的行为。常见的预测方法(模型)有曲线拟合<sup>[1]</sup>、自回归滑动平均(auto-regressive and moving average,简称ARMA)(p,q)模型<sup>[2]</sup>、灰色系统模型、BP神经网络模型<sup>[3-4]</sup>和支持向量机<sup>[5]</sup>等,还有将信号处理方法与神经网络方法相结合的预测模型,如小波神经网络预测模型<sup>[6]</sup>。这些传统的预测方法各有优劣,建立的模型不能精确预测非平稳时间序列。ARMA(p,q)预测模型的预测精度取决于模型阶数,但模型阶数不易确定。灰色系统模型实质上是利用指数函数去逼近一个经过累加处理后的时间序列,因此它仅能描述一个时间按指数规律变化的过程。如果在不了解数据序列变化的情况下采用该方法,存在预报模型不准确的问题,且灰色理论并未说明逼近的近似程度。BP神经网络预测算法需要训练的样本足够多,且具有局部极小点、过学习以及结构和类型的选择过分依赖于经验等缺陷。支持向量机理论如何根据具体问题选择适当的内积函数,选择不同的参数及其不同的参数对预测效果的影响还有待进一步研究。小波神经网络中小

波变换的有效性取决于小波分解层数和小波基的选择,不能保证信号的最优分解。因此,如何提高对非平稳信号的预测精度一直是研究的难点。经验模态分解<sup>[7-8]</sup>是一种处理非线性、非平稳信号的方法。

笔者利用EMD在处理非平稳信号方面的特性,结合RBF神经网络非线性逼近能力,将EMD与RBF神经网络方法相结合,提出了基于EMD-RBF神经网络的两种时序预测模型。

## 1 基于EMD-RBF神经网络预测模型

基于EMD-RBF神经网络的预测模型的基本思想是利用EMD将输入信号分解为多个能表征原信号内在特征时间序列的特性,结合EMD过程的完备性,对原信号的预测实际上就是对各IMF预测之和。为了提高运算效率,利用EMD的滤波器性能,将时频特性相近的IMF进行分类组合,对各类信号分别建立相应的预测模型,这样不但可以提高模型的预测精度,也使预测模型数量和规模都得到缩减。

设将 $N_c$ 个本征模式函数及趋势项分成 $l$ 组。令 $C_i = [c_{n_{i-1}}, \dots, c_{n_i}]$ ,  $i = 1, \dots, l$ ,  $n_0 = 1$ ,  $n_l = N_c + 1$ ,则分组为 $\{[C_1], [C_2], \dots, [C_l]\}$ ,预测模型如图1所示。

各组的预测目标值 $t'_i(k)$ 为

\* 学院创新性基础研究基金资助项目(编号:XY2009JJB33)

收稿日期:2011-12-02;修改稿收到日期:2012-02-20

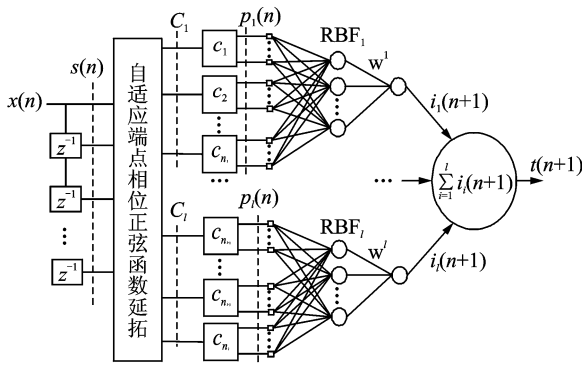


图1 基于IMF分类组合-RBF神经网络预测模型

$$t'_i(k) = \begin{cases} \sum_{j=n_{i-1}}^{n_i} c_j(k+1) & (i < n_l) \\ \sum_{j=n_{i-1}}^{n_l} c_j(k+1) + r(k+1) & (i = n_l) \end{cases} \quad (1)$$

第*i*组RBF神经网络样本提取方法为:从 $C_i$ 组内各IMF中提取数据长度为 $d$ 的数据序列作为RBF预测神经网络的输入 $p_i(k)$ , $d$ 通过统计最优确定,则

$$p_i(k) = [c_{n_{i-1},k}, \dots, c_{n_{i-1},k-d+1}, c_{n_{i-1}+1,n}, \dots, c_{n_{i-1}+1,k-d+1}, \dots, c_{n_i,k}, \dots, c_{n_i,k-d+1}] \quad (2)$$

第1个输入样本为 $p_i(d)$ ,与式(2)对应的输出样本为 $t'_i(d)$ ,则第*i*个RBF预测神经网络输入输出样本对矩阵 $P_i, T_i$ 分别为

$$\left. \begin{aligned} P_i &= \begin{bmatrix} p_i(d) \\ p_i(d+1) \\ \vdots \\ p_i(n-1) \end{bmatrix}^T \\ T_i &= \begin{bmatrix} t'_i(d+1) \\ t'_i(d+2) \\ \vdots \\ t'_i(n) \end{bmatrix}^T \end{aligned} \right\} \quad (3)$$

整个模型的输出为个分组预测模型输出之和,整体预测目 $t'(k)$ 为

$$t'(k) = \sum_{j=1}^l t'_j(k) \quad (4)$$

此时第*i*个RBF预测模型架构为 $(n_i - n_{i-1} + 1) \times d_i - n_{rbf} - 1, i = 1, 2, \dots, l, n_{rbf}$ 为径向基神经元个数,整个预测模型共有*l*个网络。基于EMD-RBF神经网络预测方法的步骤为:

1) 提出采用自适应端点相位正弦函数延拓(adaptive terminal phase sine extending,简称ATPSE)改进EMD端点效应问题。采用文献[9]的

局域中值定理分解方法改进EMD包络拟合问题。采用文献[10]的EEMD算法改进EMD模态混叠问题,提出基于自适应正弦函数延拓的集成经验模态分解(noise-assisted EMD,简称NEMD)。

不同幅值、频率和相位的正弦延拓函数对端点效应的消除有很大差异<sup>[11]</sup>,笔者提出的自适应端点相位正弦函数延拓EMD分解方法不仅较好地解决了信号端点效应,且对EMD的精度也有较大提高。采用的延拓函数及参数定义为

$$x_i(t) = A_i \sin(2\pi t/T_i + \Phi_i) + M_i \quad (i = 1, 2) \quad (5)$$

$$T_i = u_i \left| \text{time}(p_{\max}(j)) - \text{time}(p_{\min}(j)) \right| \quad (6)$$

$$A_i = b_i \left| x(p_{\max}(j)) - x(p_{\min}(j)) \right| \quad (7)$$

由式(5)~式(7)可得

$$M_i = x(p_{\max}(j)) - A_i \quad (8)$$

$$\Phi_i = \arcsin((x(j) - M_i)/A_i) \quad (9)$$

其中: $i=1$ 时 $j=1, i=2$ 时 $j=\text{end}$ ;  $x, x_1$ 和 $x_2$ 分别为待分解信号、前向和后向延拓函数; $T, u_i$ 和 $b_i (i=1, 2)$ 分别为延拓函数的周期、一个大于2的延拓周期个数比例系数和延拓函数幅值比较系数; $p_{\max}(i), p_{\min}(j), \text{end}$ 分别为局部极大值、极小值位置数列及序列长度。

被分解的信号确定以后通过选定 $u_i$ ,则整个延拓信号就出来了。

利用中值定理求任意两极值点间的局部中值为

$$e(t\xi) = \frac{1}{t_{i+1} - t_i + 1} \sum_{l=i}^{i+1} s(t_l) \quad (10)$$

其中: $s(t_l)$ 为信号; $t_i, t_{i+1}$ 为两个极值点的时刻。

由于两极值点间的数据一般是均匀变化的,因此 $t\xi = (t_i + t_{i+1})/2$ ,极值点 $t_{i+1}$ 时刻的均值为

$$m(t_{i+1}) = h(t_i)e(t\xi) + h(t_{i+1})e(t\xi + 1) \quad (11)$$

其中: $h(t_i) = \frac{t_{i+2} - t_{i+1}}{t_{i+2} - t_i}; h(t_{i+1}) = \frac{t_{i+1} - t_i}{t_{i+2} - t_i}; t_i$ 为第*i*个极值点的时间位置。

利用中值定理原理,求极值点均值时使用局部信号中的所有数据得到正确的局部均值。使用波形匹配的方法能有效抑制边界效应,提高数据分解精度和时频分辨率。

在EMD应用中经常会发生模态混叠现象,这主要是由波形突变引起的。噪声会引起局部极值发生变化,加上噪声本身的随机性使EMD结果不稳定,以致产生模态混叠现象。这为利用噪声来消除EMD的模态混叠现象提供了一种思路:在EMD前,先给信号叠加一定幅值的辅助白噪声,再进行

EMD分解,如此对同一信号反复进行多次辅助噪声EMD分解后,再对各次结果对应的IMF求均值,以均值作为原信号EMD分解的最终值就可以消除模态混叠现象。该方法的依据是通过多次叠加一定幅值的辅助噪声,使得信号EMD分解时所有可能的模态混叠现象都显现出来,而各次EMD结果间的差异是由辅助噪声引起的,不变之处在于具有明确物理意义的信号本身。虽然各次EMD分解对应IMF间差异可能较大,但由于各次叠加的辅助噪声相互独立,它们在求均值过程中被滤除,只留下具有明确物理意义的信号本身。由于该方法通过引入噪声来辅助EMD分解,故将该方法称为集成经验模态分解。

基于自适应正弦函数延拓的NEMD过程的步骤为:a.确定周期延拓比例系数 $\eta$ 和延拓时间长度系数 $\lambda$ ;b.向待处理信号叠加一小幅值的随机白噪声,进行ATPSE-EMD分解;c.重复步骤b. $N$ 次;d.对 $N$ 次结果对应的IMF求均值,以均值作为原信号EMD的最终值。需要提出的是,叠加了辅助噪声后,各次EMD的IMF个数可能略有差异,当某次EMD的IMF个数少于最多一次IMF个数时,将其不足部分IMF补零以便于均值运算。当然,最后获得的各时间序列不一定满足IMF的条件。利用以上改进的EMD算法对数据序列 $s(n)$ 进行分解。

2) 确定RBF数据中心神经元的相关参数。

3) 按式(2)~式(3)求得训练样本。

4) 根据步骤2得到的最佳RBF网络模型进行预测分析。

## 2 仿真分析

为了检验本研究方法的有效性,以Mackey-Glass微分方程为例,当 $\tau \geq 17$ 时为一个混沌时间序列

$$\frac{dx(t)}{dt} = \frac{0.2x(t-\tau)}{1+x^{10}(t-\tau)} - 0.1x(t) \quad (12)$$

为了验证提出的预测方法,取 $\tau=17$ , $x(0)=0.5$ , $t < 0$ 时 $x=0$ ,按采样频率 $f_s=1\text{Hz}$ 采样500点数据,前400点用于训练模型,后100点用于测试模型,以预测值与实际值间的平均误差、最大绝对误差和均方差(MSE)作为预测模型性能的衡量标准。利用改进EMD对样本信号进行分解,如图2所示,共有6个IMF分量及一个趋势项。

从图2可以看出: $c_1$ 波动频率较高; $c_2$ 具有明显的周期特性; $c_3$ 和 $c_4$ 波形比较相近; $c_5$ 和 $c_6$ 可看作长周期波形。根据各IMF的波形特征可将EMD结果分成4组 $\{[c_1],[c_2],[c_3,c_4],[c_5,c_6,r]\}$ 。通过测试最优值取 $d=3$ ,第1、第2组RBF神经网络聚类个数取




图2 仿真信号EMD结果

20,第3、第4组RBF神经网络聚类个数取10时,采用本研究方法提出的EMD-RBF神经网络预测模型对式(14)中的仿真信号进行预测,各组实际值、预测值与误差分别如图3~图6所示。各组预测结果组合为最终预测结果,如图7所示。BP神经网络预测结果如图8所示。各预测方法的性能如表1所示。从图7、图8和表1可以看出,基于EMD-RBF预测方法的精度要明显高于传统BP预测方法。




图3  $C_1$ 及其预测、误差曲线




图4  $C_2$ 及其预测、误差曲线




图5  $C_3$ 和 $C_4$ 组合及其预测、误差曲线


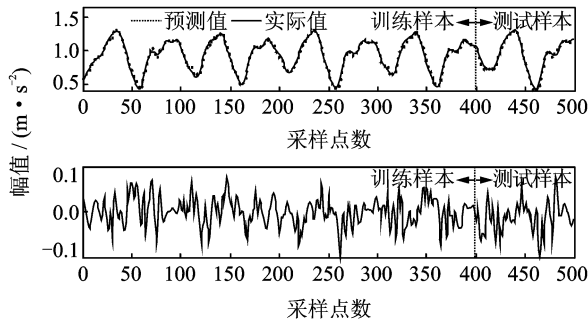
图6  $C_5, C_6, r$  组合及其预测、误差曲线

图7 IMF 分类预测合成信号及其与原信号的误差曲线




图8 BP 神经网络预测及其误差曲线

表1 EMD-RBFNN 预测性能和BPNN 预测性能对比

分组	IMF	预测模型	测试样本 MSE	最大 误差	平均 误差
1	$C_1$	(RBF)	$6.4 \times 10^{-5}$	0.017 7	0.005 8
		$1 \times 3 : 20 : 1$			
2	$C_2$	(RBF)	$1.616 \times 10^{-4}$	0.065 0	0.024 7
		$1 \times 3 : 20 : 1$			
3	$C_3, C_4$	(RBF)	$5.094 \times 10^{-5}$	0.017 0	0.005 7
		$2 \times 3 : 10 : 1$			
4	$C_5, C_6$	(RBF)	$3.147 \times 10^{-6}$	0.002 9	0.001 4
		$2 \times 3 : 10 : 1$			
合成整体		(RBF)	$2.66 \times 10^{-5}$	0.039 4	0.012 5
		合成			
		(BP)			
		$20 : 5 : 1$	$1.3 \times 10^{-3}$	0.091 8	0.027 3

文献[6]应用模型如图9所示的小波包分解与

BP神经网络相结合的预测方法,对同样的数据段进行仿真分析,如表2所示(文献[6]只给出了预测值与实际值间的均方差)。对比表1和表2可以看出,笔者提出的基于EMD-RBF分类组合预测方法性能更优,进一步证明了本研究方向方法的优越性。

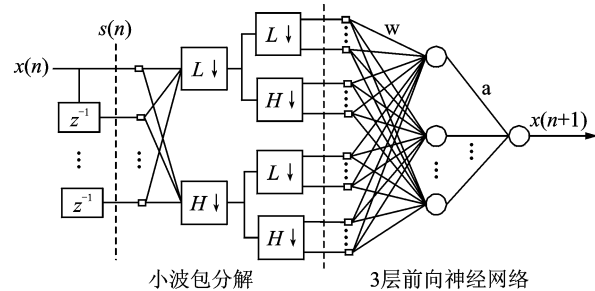


图9 小波神经网络预测模型

表2 基于小波包分解与BP网络的预测性能参数

小波BP神经网络预测模型	均方差	14 : 2 (Db2) : 8	14 : 3 (Db2) : 8
	$4.17 \times 10^{-4}$	$7.86 \times 10^{-5}$	$3.62 \times 10^{-4}$

数据窗口长度 : 分解层数(小波类型) : BPNN的隐层单元数目

仿真结果表明,各IMF分类组合预测方法考虑到各IMF本身的特性,为具有类似时频特性的IMF分别建立预测模型,增强了时序的可预测性,提高了时间序列预测精度,适用于对预测精度要求高的场合。

### 3 实例分析

武器装备对环境温度要求非常高,温度高低直接影响装备仪器性能,这就要求对装备温控系统性能进行有效监测,而预测方法就是一种故障预警的有效手段。某装备温度传感器最大误差不超过 $\pm 0.1^\circ\text{C}$ ,为确保预测数据有效性,要求预测精度绝对误差同样不超过 $0.1^\circ\text{C}$ 。通过在正常状态下建立的某温度传感器预测模型预测同一次操作时段内该传感器其他部分的数据。若预测值与实际值间差值不超过 $0.1^\circ\text{C}$ ,就认为温控部分和温度传感器状态正常,否则就认为温控部分或者温度传感器有可能出现故障,需要对其进行检查。

现有一正常状态下600点的温度传感器采样信号,采用IMF分类组合RBF预测模型将前400点用于训练预测模型,后200点数据用于测试预测模型。原信号EMD分解共有6个IMF和一个趋势项,如图10所示。根据分解信号的波形相似度、频率成分以

及IMF间的相关性,将 $C_3$ 与 $C_4$ 分组、 $C_5$ 与 $C_6$ 分组,合并后的各IMF分量与真实信号的偏差较小,这样的分组相当于对预测样本进行了聚类处理,有利于减少预测神经网络的样本数,提高预测神经网络的运算速度和精度。若将 $C_2$ 与 $C_3$ 分为一组, $C_4$ 与 $C_5$ 分为一组,虽然两组的波形相似,但 $C_2$ 和 $C_3$ 组、 $C_4$ 和 $C_5$ 组之间的IMF间的相关性小于 $C_3$ 和 $C_4$ 组、 $C_5$ 和 $C_6$ 组,不恰当的分组会使各IMF分量失去分解的物理意义,同时也会影响预测的精度。




图10 某装备实测信号的改进EMD分解结果

针对各IMF时频特性差异较大的特点,对多数IMF进行独立预测分析,各类预测模型、预测性能及合成预测性能如表3所示。所有模型数据窗口长度统一取为3,合成预测信号及其误差曲线如图11所示。

表3 EMD分类组合-RBFNN预测性能

分组	IMF	RBF预测模型	测试样本MSE	最大误差	平均误差
1	$C_1$	$1 \times 3 : 20 : 1$	$3.1689 \times 10^{-4}$	0.0369	0.0145
2	$C_2$	$1 \times 3 : 20 : 1$	$6.829 \times 10^{-5}$	0.0231	0.0065
3	$C_3$	$1 \times 3 : 20 : 1$	$8.7664 \times 10^{-6}$	0.0098	0.0022
4	$C_4$	$1 \times 3 : 20 : 1$	$1.8938 \times 10^{-6}$	0.0031	0.0011
5	$C_5, C_6$	$2 \times 3 : 10 : 1$	$1.7053 \times 10^{-4}$	0.0203	0.0113
合成		5组合成	$3.594 \times 10^{-4}$	0.0572	0.0101




图11 某装备温度信号及其预测、误差曲线

从表3和图11可知,基于EMD-RBF分类组合预测方法最大预测误差远小于传感器误差,说明将该方法应用在某装备温控系统性能监测中是可行的。

## 4 结论

1) 提出了一种基于EMD与RBF神经网络的预测方法,该方法结合EMD和RBF神经网络的优点,利用EMD的滤波器性能,将时频特性相近的IMF进行分类组合,对各类信号分别建立相应的预测模型后重构原始信号最终预测结果,提高了预测模型的精度。

2) 针对EMD-RBF神经网络隐含神经元数目及其中心数据选取问题,以最小化训练样本预测值与实际值间的最小方差为训练目标,提出基于统计分析的k-均值聚类方法自适应地确定满足训练目标的RBF模型参数,该方法可以自适应地建立起相应的预测网络模型,参数选取不需要人为介入,实用性强。

3) 仿真结果表明,该方法充分考虑到各IMF本身的特性,增强了时序的可预测性,预测性能比传统BP神经网络和小波BP神经网络更优越。将该方法应用在某装备温控系统性能监测中,其温度参数最大预测误差远小于传感器误差,说明将该方法用于装备故障预测中是可行的。

## 参 考 文 献

[1] Moghram I, Rahman S. Analysis and evaluation of five short-term load forecasting techniques[J]. IEEE Trans Power Systems, 1989, 14(4):1484-1491.

[2] Huang S J, Shih K R. Short-term load forecasting Via ARMA model identification including non-gaussian process considerations[J]. IEEE Trans Power Systems, 2003, 18(2):673-679.

- [3] Saini L M, Soni M K. Artificial neural network-based peak load forecasting using conjugate gradient methods[J]. IEEE Trans on Power Systems, 2002, 12(3): 907-912.
- [4] Kim K H, Youn H S, Kang Y C. Short-term load forecasting for special days in anomalous load conditions using neural networks and fuzzy inference method[J]. IEEE Trans on Power Systems, 2000, 15(2): 559-565.
- [5] Cheng Junsheng, Yu Dejie, Yang Yu. Application of support vector regression machines to the recessing of end effects of Hilbert-Huang transform[J]. Mechanical Systems and Signal Processing, 2007(21): 1197-1211.
- [6] Teo K K, Wang Lipo, Lin Zhiping. Wavelet packet multi-layer perceptron for chaotic time series prediction: effects of weight initialization[C]//Proceedings of International Conference of Computational Science ICCS 2001. San Francisco: [s. n.], 2001: 310-317.
- [7] Huang N E, Shen Zheng, Long S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[J]. Procedures of the Royal Society of London, Series A, 1998, 454: 903-995.
- [8] Rilling G, Flandrin P, Goncalves P. On empirical mode decomposition and its algorithms[C]//IEEE-EURASIP Workshop on Nonlinear Signal and Image Processing NSIP-03. Grado, Italy: [s. n.], 2003: 8-11.
- [9] 盖强, 马孝江, 张海勇, 等. 几种局域波分解方法的比较研究[J]. 系统工程与电子技术, 2002, 24(2): 57-59.  
Gai Qiang, Ma Xiaojiang, Zhang Haiyong, et al. Comparing study for decomposing methods using local wave method[J]. Journal of Systems Engineering and Electronics, 2002, 24(2): 57-59. (in Chinese)
- [10] Wu Zhanhua, Huang N E. Ensemble empirical mode decomposition: a noise-assisted data analysis method[J]. Advances in Adaptive Data Analysis, 2009, 1(1): 1-41.
- [11] 韩建平, 钱炯, 董小军. 采用镜像延拓和RBF神经网络处理EMD中端点效应[J]. 振动、测试与诊断, 2010, 30(4): 414-417.  
Han Jianping, Qian Jiong, Dong Xiaojun. Suppression of end-effect in empirical mode decomposition by mirror extension and radial basis function neural network prediction[J]. Journal of Vibration, Measurement & Diagnosis, 2010, 30(4): 414-417. (in Chinese)



**第一作者简介:**李方溪,女,1976年6月生,博士研究生。主要研究方向为机械设备状态监测与故障诊断、信号采集与处理。

E-mail:fang\_li999@yhoo.com.cn