

# 环境激励下桥梁结构信号分解与模态参数识别\*

陈永高<sup>1</sup>, 钟振宇<sup>1,2</sup>

(1. 浙江工业职业技术学院建筑工程学院 绍兴, 312000) (2. 浙江大学建筑工程学院 杭州, 310058)

**摘要** 为实现环境激励下桥梁结构信号分解与模态参数识别的一体化, 首先, 针对现有集合经验模态分解算法存在的端点效应和有效本征模态函数筛选难的问题, 通过引入镜像延拓算法和支持向量回归机算法来抑制端点效应, 并根据互相关系数和能量系数建立筛选有效本征模态函数的新指标——有效系数; 其次, 根据桥梁结构真实模态存在的一般规律提出了用于智能化辨识稳定图中真实模态的算法; 最后, 通过某大型斜拉桥振动台试验来验证所提算法的可行性。结果表明, 所提算法不仅能实现桥梁结构响应信号的自适应分解和重构, 还能实现稳定图中真实模态的智能化筛选, 即实现桥梁结构模态参数的智能化识别, 且识别结果具有可靠性。

**关键词** 桥梁结构; 信号分解; 信号重构; 端点效应; 参数识别

**中图分类号** U446.3

## 引言

模态参数识别作为桥梁结构健康监测<sup>[1]</sup>的重要组成部分, 实际运用中可通过识别桥梁结构的模态参数<sup>[2]</sup>来评估结构自身的使用性能。在利用这一特性对大型桥梁结构进行健康监测时, 由于结构上传感器采集的是环境激励下的结构响应, 其内部含有大量噪声, 噪声的存在会直接影响参数识别结果的精确性。虽然集合经验模态分解算法<sup>[3]</sup> (ensemble empirical mode decomposition, 简称 EEMD) 能够运用于消除部分噪声, 但其依然存在如下两方面的不足: 端点效应现象<sup>[4]</sup> 和本征模态函数 (intrinsic mode function, 简称 IMF) 的筛选<sup>[5]</sup>。虽然有不少学者对这两方面的问题提出了自己的处理方法<sup>[6]</sup>, 但处理的效果并不理想。

对于结构的模态参数识别, 现阶段最为常用的算法是随机子空间识别法<sup>[7]</sup> (stochastic subspace identification, 简称 SSI)。该算法是 Peeters 等<sup>[8]</sup>提出的一种基于离散时间状态空间方程的算法, 针对其主要缺陷在于需要人为参与稳定图中真实模态筛选的问题, 禹丹江等<sup>[9]</sup>提出了基于经验模态分解 (empirical mode decomposition, 简称 EMD) 和 SSI 的环境激励模态参数识别算法, 并将该方法用于实

桥环境振动试验中。文献<sup>[10-11]</sup>将谱系聚类算法与 SSI 相结合。虽然不少学者对 SSI 算法的缺陷进行了改进, 但却忽略了结构真实模态存在的一般规律。基于此, 笔者总结了结构真实模态存在的一般规律, 并提出了以频率、阻尼比以及振型为判别因子的真实模态筛选算法。

为实现结构响应信号分解和模态参数识别的一体化, 将改进的信号分解算法与改进的模态参数识别算法进行有效结合。首先, 利用信号分解算法对响应信号进行自适应分解与重构; 其次, 再对重构信号进行模态参数自动化识别, 以实现结构信号分解与参数识别的一体化; 最后, 将所提算法运用于识别大型斜拉桥振动台试验数据, 并对比分析所得结果以验证所提算法是否具有可行性。

## 1 集合经验模态分解的改进

随着集合经验模态分解算法的不断使用, 其缺陷<sup>[3]</sup>也逐渐明显, 包括: a. 端点效应的处理效果不理想; b. 信号分解之后无法实现有效 IMF 分量的智能化辨识, 需人为参与辨识, 这样不仅降低了信号分解效率, 还会因辨识人的认知水平具有差异性导致筛选的 IMF 分量存在一定的主观性。鉴于此, 提出了处理这两问题的相应算法。

\* 浙江省教育厅科研资助项目 (Y201432555); 浙江省住建厅科研资助项目 (2014Z126); 绍兴市科技计划资助项目 (2014B70003)

收稿日期: 2017-02-19; 修回日期: 2017-05-21

## 1.1 端点效应处理

现阶段常用的端点效应处理算法包括:a. 基于镜像延拓<sup>[12]</sup>的端点效应处理算法,该算法的主要缺点在于使用过程中需不断平移“镜面”,当遇到短序列信号时,则端点效应处理效果较差;b. 基于支持向量回归机<sup>[13]</sup>的端点效应处理算法,同样存在处理效果较差的现象。

研究分析发现,可将镜像延拓算法和支持向量回归法进行结合来处理端点效应。两者算法的具体耦合过程如下:

1) 分析待分解信号在端点处的极值点分布情况;

2) 将分解信号内部的数据点  $l_1, l_2, \dots, l_n$  作为样本点,根据一定的先后顺序从中选取  $N$  组训练样本,构建训练集  $F$ ,其表达式为

$$\begin{cases} F = \{(\bar{x}_1, y_1), (\bar{x}_2, y_2), \dots, (\bar{x}_N, y_N)\} \\ \bar{x}_i = [l_i, l_{i+1}, \dots, l_{n-N+i-1}] \\ y_i = l_{n-N+i} \end{cases} \quad (1 \leq i \leq N) \quad (1)$$

3) 构建回归模型,并计算待分解信号在左端点外的第1个极值点  $l_z$ ;

4) 根据步骤2~3,计算出待分解信号在右端点外的第1个极值点  $l_y$ ;

5) 利用镜像延拓法处理延拓后的待分解信号  $(l_z, l_1, l_2, \dots, l_n, l_y)$ ,将其映射成一个不存在端点的环形闭合信号。

分析上述算法流程不难发现,提出的基于镜像延拓和支持向量回归法的处理方法具有以下两方面的优点:

1) 步骤3和4中仅预测延拓了信号在两端点外的一个极值点,延拓的点数越少,则预测的误差也就越小;

2) 利用步骤5对信号进行镜像延拓,能增加信号本身的长度,且在分解过程中一旦镜面的位置被确定,便无需对其进行移动。

对于端点效应处理效果的评价<sup>[4]</sup>,现阶段一般通过直接观察法进行辨识。为了能对其进行定量评价,引入了用于评价端点效应处理好坏的评价指标  $\theta$ ,其算法步骤如下。

1) 分别计算各IMF分量与待分解信号间的均方根有效值RMS,以评估各分量的能量大小

$$RMS = \sqrt{\frac{\sum_{i=1}^n S^2(i)}{n}} \quad (2)$$

其中: $S(i)$ 为待分解信号 $x(t)$ 的各分解结果; $n$ 为信号采样点数。

2) 根据式(3)计算最终的评价指标  $\theta$

$$\theta = \left| \sum_{i=1}^k RMS_i - RMS_n \right| / RMS_n \quad (3)$$

其中: $RMS_n$ 为待分解信号对应的有效值; $RMS_i$ 为IMF $i$ 分量对应的有效值; $k$ 为IMF分量总个数。

根据式(3)可知,评价指标 $\theta$ 越大,则表明端点效应影响越大。

## 1.2 信号重构

要实现信号的自动化重构需要从分解结果中提取有效的IMF分量,现阶段对有效IMF分量的筛选并没有统一的标准。林丽等<sup>[14]</sup>提出利用“相关系数”。陈仁祥等<sup>[15]</sup>指出利用“能量密度与其平均周期的乘积为一常量”这一特点。

为了实现有效IMF分量的智能化辨识,提出了一种新筛选算法,该算法能兼顾IMF分量与原始信号之间的相关程度以及IMF分量各自的能量密度和平均周期。其具体实现流程如下。

1) 根据相关系数准则,求取各IMF分量与原始信号之间的关联程度。首先,分别求解出各IMF分量的互相关函数 $R_j$ 和原始信号的自相关函数 $R_x$

$$R(m) = \frac{1}{N} \sum_{i=0}^{N-1} s(i)s(i+m) \quad (4)$$

其中: $s(i)$ 为信号各时刻的数值; $m$ 为信号的长度。

其次,对 $R_x$ 进行归一化处理求出 $R_j$ 和 $R_x$ 的互相关系数 $r_j$

$$r_j = \frac{\sum_{i=1}^{2N-1} R_j(i)R_x(i)}{\sqrt{\sum_{i=1}^{2N-1} R_j^2(i) \sum_{i=1}^{2N-1} R_x^2(i)}} \quad (5)$$

其中: $j$ 为分量总数。

2) 求解各IMF分量自身的能量密度和平均周期,利用式(6)计算各IMF分量对应的能量密度 $E$ 、平均周期 $\bar{T}$ 以及能量系数ET

$$\begin{cases} E_j = \frac{1}{N} \sum_{i=1}^N (f_j(i))^2 \\ \bar{T}_j = 2N/O_j \\ ET_j = E_j \bar{T}_j \end{cases} \quad (6)$$

其中: $N$ 为原始信号长度; $f_j$ 为第 $j$ 个IMF分量的振幅值; $O_j$ 为第 $j$ 个IMF分量存在的极值点个数。

3) 根据互相关系数和能量系数计算用于筛选有效IMF分量的新指标—有效系数SX

$$SX_j = r_j \left| \frac{ET_j - \frac{1}{j-1} \sum_{i=1}^{j-1} ET_i}{\frac{1}{j-1} \sum_{i=1}^{j-1} ET_i} \right| \quad (7)$$

当  $SX_j$  越接近 1 时,代表第  $j$  个 IMF 分量是有效 IMF 分量的几率更大,认为  $0.6 \leq SX \leq 1$  时<sup>[15]</sup>,对应的 IMF 量属于有效成分,可用于信号的重构。

4) 利用式(8)对有效 IMF 分量进行重构,以实现信号的自动化重构

$$\tilde{x}(t) = \sum_{i=1}^k \text{imf}_i \quad (8)$$

其中:  $\tilde{x}(t)$  为重构的信号;  $k$  为保留下来的有效 IMF 分量的个数。

## 2 真实模态智能化辨识

随机子空间法 (SSI) 适用于线性系统,其不仅能有效地识别出环境激励下的结构动力特性,且无需事先由响应数据得到自由衰减曲线。该算法分为两类:基于协方差驱动随机子空间识别法 (covariance driven stochastic subspace identification, 简称 COV-SSI) 和基于数据驱动随机子空间识别法 (data driven stochastic subspace identification, 简称 DATA-SSI)。对比这两种分解算法对应的理论可知,COV-SSI 在参数识别过程中会计算协方差,能在一定程度上提高参数识别的精确性,因此以 COV-SSI 来进行参数识别,其算法步骤详见文献[7]。

### 2.1 稳定图理论

无论是运用 COV-SSI 还是 DATA-SSI 对结构进行模态参数识别都面临同样的难题,即如何筛选真实模态。基于此,首先简单分析稳定图相关理论,再详细分析如何从稳定图中筛选属于结构自身的真实模态。

假定频率对应的容差为  $\Delta_f$ , 阻尼比对应的容差为  $\Delta_\xi$ , 模态振型对应的容差为  $\Delta_\psi$ , 稳定点需满足的条件为

$$\begin{cases} (f^j - f^{j+1})/f^j \times 100\% < \Delta_f \\ (f^j - f^{j+1})/f^j \times 100\% < \Delta_f \\ (1 - \text{MAC}(j, j+1)) \times 100\% < \Delta_\psi \end{cases} \quad (9)$$

其中:  $j$  为模型的阶数;  $f, \xi, \psi$ : 分别为各阶次对应的频率、阻尼比和振型; MAC 为模态置信因子。

实际应用中由于人们对阻尼比的认识水平还不够,且其容易受外界因素的影响,频率值的容差小于阻尼比对应的容差,分别为 1% 和 5%。

### 2.2 真实模态智能化辨识

在利用 COV-SSI 对桥梁结构进行模态参数识别时,需人为参与稳定图中真实模态和虚假模态的

辨识,由于个人间的差异性会导致识别出的真实模态具有主观性。基于此,引入了一种能实现真实模态智能化筛选的算法,在介绍该算法之前,需了解结构真实模态存在的一般规律。笔者对多个结构在连续一段时间内对应的多幅稳定图进行对比分析发现:对于同一桥梁结构而言,其自身的结构特性在短时间内并不会发生较大的变化,即该结构对应的频率值、阻尼比以及模态振型在短时间内处于稳定状态;从数值上来看,表现为数值大小不会有较大的变化,只有虚假模态会随着噪声等因素的影响而发生较大变化。基于这一特性,可以从多幅稳定图中筛选稳定的模态作为结构的真实模态。

为了从多幅稳定图中筛选出真实模态,提出了一种筛选算法,即以稳定图中频率值、阻尼比以及振型系数为判别因子建立判别矩阵,并根据一定的判断准则来筛选在多幅稳定图中均出现了的模态参数值,并保留这部分模态参数作为最终的真实模态。下面详细分析该算法的具体实现步骤。

1) 对桥梁结构进行多次参数识别,假定识别次数为  $N$  次,即能够识别出  $N$  组参数结果,将每组识别结果记为  $X_i$

$$X_i = \{f_i \quad r_i \quad m_i\} \quad (i=1, 2, \dots, N) \quad (10)$$

其中:  $f_i$  为频率值;  $r_i$  为阻尼比;  $m_i$  为振型系数。

2) 以  $f_i, r_i$  以及  $m_i$  为判别因子,计算连续两时间段内模态参数的欧式距离,以便实现真实模态的辨识。

定义第  $i$  次结果  $X_i$  中第  $A$  阶模态与第  $j$  次结果  $X_j$  中第  $B$  阶模态的判别矩阵为  $D_{ABij}$ , 通过观察  $D_{ABij}$  中的数值大小来辨别  $A, B$  阶模态是否属于同一类的模态参数,判别矩阵计算式为

$$D_{ij}^{AB} = \left( \sqrt{\sum_{k=1}^n (f_i(A, k) - f_j(B, k))^2} + \sqrt{\sum_{k=1}^n (r_i(A, k) - r_j(B, k))^2} + \sqrt{\sum_{k=1}^n (m_i(A, k) - m_j(B, k))^2} \right) / 3 \quad (11)$$

当  $0.8 \leq D_{ij}^{AB} \leq 1$  时,可认为第  $i$  次结果  $X_i$  中第  $A$  阶模态与第  $j$  次结果  $X_j$  中第  $B$  阶模态属于同一类。为了实现筛选出这  $N$  组参数结果中的所有同类项,提出了如下算法流程:

1) 首先将 1, 2 组结果中的同类项聚为一类,其次再将其与剩余的模态进行组合,构建新一组新的模态参数结果  $XX_2$ ;

2) 将参数结果  $XX_2$  与第 3 组参数结果  $X_3$  按照步骤 1 进行判别分析,并再次构建一组新的参数

结果  $XX_3$ ; 按照这一规律, 依次类推, 直到将  $N$  组参数结果都进行判别分析, 得到最终的一组参数结果  $XX_N$ ;

3) 对  $XX_N$  中的每阶模态进行聚类个数的统计, 即统计每阶模态是由多少组结果聚类而成, 筛选出聚类个数大于等于  $0.6N$  [11] 的那些阶次, 并将其绘制于稳定图中。

通过上述建立的判别矩阵便能实现真实模态的智能化筛选和虚假模态的剔除。为实现信号分解与模态参数识别的一体化处理, 可基于图 1 所示流程图进行信号的分解和模态参数识别。

### 3 大型桥梁中的应用

为验证所提算法的可行性, 现以大型斜拉桥振动台试验为研究对象, 先分别运用 EEMD 和改进 EEMD 对传感器采集的加速度响应信号进行处理, 再利用 COV-SSI 对重构信号进行模态参数识别, 并结合提出的真实模态筛选算法进行模态参数的智能化识别。

#### 3.1 试验桥工程概况

图 2 为试验桥梁的立面图, 将该试验桥放置于振动台上, 利用振动台对其进行激励的输入, 并采集各关键点处对应的竖向加速度信号。加速度传感器布置的具体位置如图 3 所示。

对该试验桥进行 10 组工况下的测试, 采样频率均为 20 Hz, 且各工况采样时间为 100 min。笔者仅选取输入为白噪声的 6 组工况进行分析, 试验工况见表 1, 图 4 为某工况下前 100 s 主梁跨中的竖向加速度响应信号。

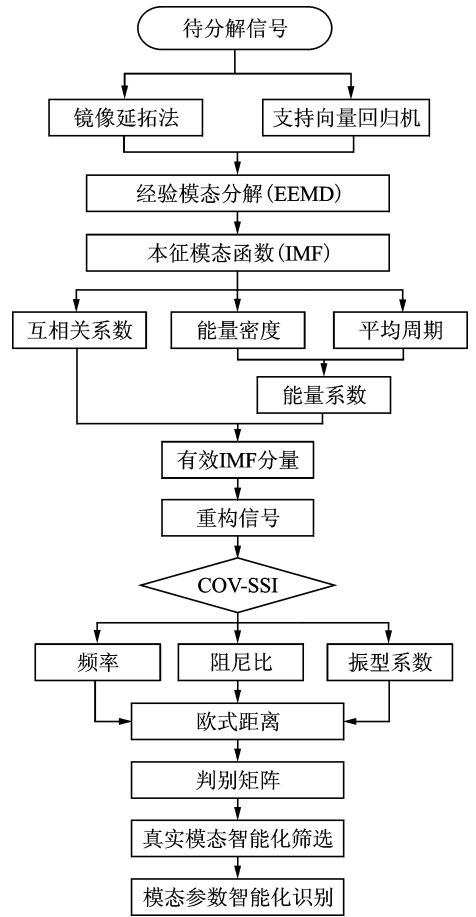


图 1 流程图  
Fig. 1 Flowchart




图 2 立面图(单位: cm)  
Fig. 2 Elevation (unit: cm)

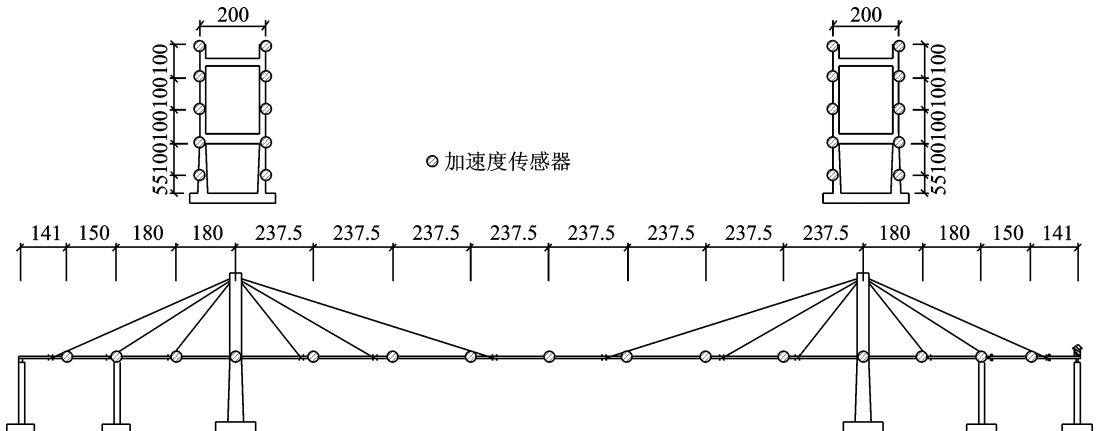


图 3 加速度传感器布置图(单位: cm)  
Fig. 3 Layout of accelerometer (unit: cm)

表 1 试验工况表

Tab.1 Working condition of test

工况号	工况名	地震输入方向	输入波形	峰值加速度/ $g$
1	G1	竖桥向输入	白噪声	0.1
2	G10	竖桥向输入	白噪声	0.1
3	WN1	竖桥向输入	白噪声	0.1
4	WN2	竖桥向输入	白噪声	0.1
5	WN3	竖桥向输入	白噪声	0.1
6	WN4	竖桥向输入	白噪声	0.1





图 4 加速度时程曲线

Fig. 4 Acceleration-time curve



(a) 改进EEMD分解图

(a) Improved EEMD decomposition diagram


### 3.2 响应信号分解与重构

运用两种分解算法对图 4 中的信号进行分解, 得到图 5 所示结果。

EEMD 分解算法对应的评价指标  $\theta$  为 0.672, 改进 EEMD 算法对应的评价指标  $\theta$  为 0.104, 可知改进 EEMD 算法的端点效应优于 EEMD 分解算法所得结果。

为实现有效 IMF 分量的智能化筛选, 分别求解出了用于筛选有效 IMF 分量的有效系数, 结果如表 2 和表 3 所示。根据表中数据可知: IMF<sub>3</sub> ~ IMF<sub>5</sub> 为改进 EEMD 算法的有效 IMF 分量; IMF<sub>3</sub> ~ IMF<sub>6</sub> 为 EEMD 算法的有效 IMF 分量。为验证筛选出的 IMF 分量能有效反映结构的信息, 绘制了 Hilbert-Huang 谱, 如图 6 所示。

由图 6 可知:



(b) EEMD分解图

(b) EEMD decomposition diagram

图 5 信号分解结果

Fig. 5 Signal decomposition result

表2 有效系数表(改进 EEMD)


Tab. 2 The effective coefficient(improved EEMD)

各项系数	IMF <sub>1</sub>	IMF <sub>2</sub>	IMF <sub>3</sub>	IMF <sub>4</sub>	IMF <sub>5</sub>	IMF <sub>6</sub>	IMF <sub>7</sub>	IMF <sub>8</sub>	IMF <sub>9</sub>	IMF <sub>10</sub>
互相关系数	0.07	0.23	0.88	0.53	0.46	-0.24	-0.16	-0.07	0.03	0.01
能量系数	0.12	0.45	0.92	0.94	0.86	0.53	0.41	0.22	0.12	0.07
有效系数	0.10	0.34	0.90	0.74	0.66	0.15	0.13	0.08	0.08	0.04

表3 有效系数表(EEMD)


Tab. 3 The effective coefficient(EEMD)

各项系数	IMF <sub>1</sub>	IMF <sub>2</sub>	IMF <sub>3</sub>	IMF <sub>4</sub>	IMF <sub>5</sub>	IMF <sub>6</sub>	IMF <sub>7</sub>	IMF <sub>8</sub>	IMF <sub>9</sub>	IMF <sub>10</sub>	IMF <sub>11</sub>
互相关系数	0.08	0.27	0.84	0.72	0.65	0.63	0.34	0.27	0.15	0.09	0.04
能量系数	0.23	0.53	0.93	0.78	0.71	0.62	0.48	0.33	0.21	0.12	0.06
有效系数	0.16	0.40	0.89	0.75	0.68	0.63	0.41	0.30	0.18	0.11	0.05



(a) Hilbert-Huang谱(改进EEMD)

(a) Hilbert Huang spectrum (improved EEMD)



(b) Hilbert-Huang谱(EEMD)

(b) Hilbert-Huang spectrum (EEMD)

图6 Hilbert-Huang谱

Fig. 6 Hilber-Huang spectrum

- 1) EEMD 分解算法所得结果的连续性较差,低阶频率对应的 IMF 分量更为离散;
- 2) EEMD 分解结果对应的端点效应更为明显;
- 3) EEMD 算法所得有效 IMF 分量对应各阶频率的能量较低,难以反映结构的信息。

通过上述分析可知:改进 EEMD 算法不仅能实现有效 IMF 分量的自动化筛选,还能具有更好的端点效应处理效果,进而具有更好的实用性。

### 3.3 模态参数识别

以 100 s 为一个时间段,将 100 min 对应的响应信号分为 60 组,分别对每组响应信号进行模态分解和模态参数识别,可识别出 60 组参数结果。由于篇幅有限,仅罗列两幅稳定图。图 7 对应的采样时间为 0~100 s,图 8 对应的采样时间为 0~100 min。




图7 稳定图(时间段为0~100 s)

Fig. 7 Stabilization diagram (time period is 0~100 s)




图8 稳定图(时间段为0~100 min)

Fig. 8 Stabilization diagram (time period is 0~100 mins)

通过分析所得的 60 幅稳定图,得到如下结论:

- 1) 如果仅依据几幅稳定图,难以辨识出桥梁结构的全部真实模态;
- 2) 由于桥梁结构自身的特性不会随时间的推移发生较大的变化,即真实模态会在大部分的稳定

图中存在,通过观察多幅稳定图也能证实这一特性;

3) 频率段在 2~5 Hz 之间,模态混叠的现象比较严重,该频率段也越易出现虚假模态,人为筛选的模态更不具可靠性。

利用第 2.2 节提出的算法对 60 组模态参数识别结果进行真实模态的筛选,得到的稳定图如图 9 所示。




图 9 真实模态

Fig. 9 The real modes

由图 9 可知,提出的模态参数智能化识别算法能辨识出实际桥梁结构的真实模态。为进一步验证算法识别的结果具有可靠性,将识别结果与理论值进行对比分析,其中理论频率值由建立的 MIDAS 模型获得,该桥梁结构对应的 MIDAS 全桥模型如图 10 所示,图 11 为该桥梁结构前 3 阶模态振型图。参数对比分析结果见表 4,由表 4 可知,所提算法能




图 10 全桥模型

Fig. 10 Model of full-bridge

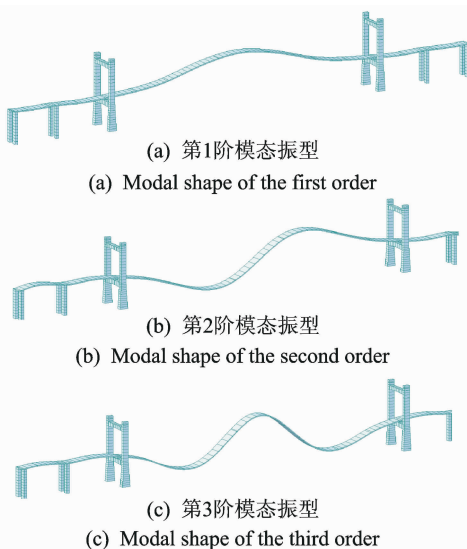


图 11 前 3 阶模态振型(MIDAS 模型)

Fig. 11 Modal shape of first three orders (MIDAS)

表 4 主梁主要自振频率

阶次	理论值	识别值	误差	误差/%
第 1 阶频率	0.181 6	0.184 5	-0.002 9	-1.57
第 2 阶频率	0.219 1	0.240 0	-0.020 9	-8.71
第 3 阶频率	0.473 1	0.463 3	0.009 8	2.12
第 4 阶频率	0.514 6	0.554 6	-0.040 0	-7.21
第 5 阶频率	0.692 8	0.706 16	-0.013 36	-1.89
第 6 阶频率	1.098 0	1.185 0	-0.087 0	-7.34
第 7 阶频率	1.754 0	1.848 0	-0.094 0	-5.09
第 8 阶频率	2.578 0	2.486 5	0.091 5	3.68
第 9 阶频率	3.356 0	3.177 9	0.178 1	5.60
第 10 阶频率	3.912 0	3.638 0	0.274 0	7.53
第 11 阶频率	4.743 0	4.328 1	0.414 9	9.59
第 12 阶频率	5.264 0	5.099 0	0.165 0	3.24

够识别出该桥梁结构前 12 阶频率值,且识别的频率结果与理论值的差距很小,最大的误差百分比为 9.6%,最小的误差百分比为 1.6%,可见所提算法能够运用于桥梁结构的模态参数识别。

为验证所提算法的有效性,得到图 12 所示前 3 阶振型图。图中横坐标为选取的 11 个传感器对应的布置位置,两边跨各对应 2 个传感器,两个主塔各对应 1 个传感器,跨中选取了 5 个传感器。将其与图 11 进行对比发现,所提算法得到的模态振型图与理论振型图相似度很高。

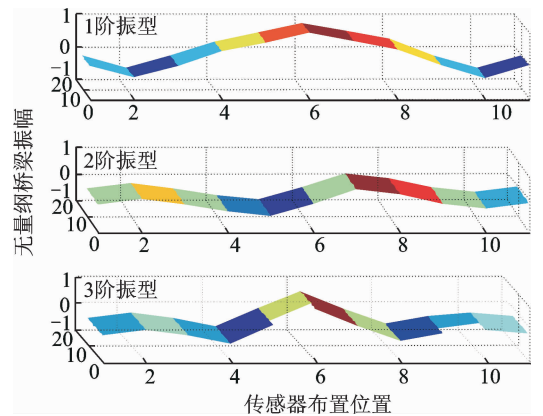


图 12 前 3 阶模态振型图

Fig. 12 Modal shape of first three orders

## 4 结 论

1) 利用支持向量回归机预测延拓待分解信号在左右两端点处的一个极值点,再利用镜像延拓算法对信号进行闭合处理,并对其进行模态分解,在一定程度上避免端点效应的存在。

2) 可以通过计算各 IMF 分量与原始信号间的互相关系数以及各 IMF 分量自身的能量密度和平均周期来筛选有效 IMF 分量。

3) 利用频率值、阻尼比以及振型系数建立判别



矩阵,并根据一定的判别准则便能实现稳定图中真实模态的智能化辨识。

4) 将所提算法运用于斜拉桥振动台试验的信号分解和模态参数识别,结果表明,所提算法不仅能实现桥梁结构响应信号的自适应分解和重构,还能实现模态参数的智能化识别,识别结果具有可靠性。

### 参 考 文 献

- [1] Huston D. Structural sensing, health monitoring, and performance evaluation[M]. New York: CRC Press Taylor and Francis, 2011:19-29.
- [2] 刘宗政,陈恩,郭德隆. 基于环境激励的桥梁模态参数识别[J]. 振动、测试与诊断, 2010, 30(3):300-303.  
Liu Zongzheng, Chen Ken, Guo Delong. Bridge modal parameters identification based on ambient excitation [J]. Journal of Vibration, Measurement & Diagnosis, 2010, 30(3):300-303. (in Chinese)
- [3] 蔡艳平,李艾华,徐斌,等. 集成经验模态分解中加入白噪声的自适应准则[J]. 振动、测试与诊断, 2011, 31(6):709-714.  
Cai Yanping, Li Aihua, Xu Bing, et al. The adaptive rule of ensemble empirical mode decomposition with added white noise [J]. Journal of Vibration, Measurement & Diagnosis, 2011, 31(6):709-714. (in Chinese)
- [4] 郑近德,程军圣,杨宇. 改进的 EEMD 算法及其应用研究[J]. 振动与冲击, 2013, 32(21):21-26.  
Zheng Jingde, Cheng Junsheng, Yang Yu. Research of improved EEMD algorithm and its application [J]. Journal of Vibration and Shock, 2013, 32(21):21-26. (in Chinese)
- [5] 时世晨,单佩韦. 基于 EEMD 的信号处理方法分析和实现[J]. 现代电子技术, 2011, 34(1):88-90.  
Shi Shichen, Shan Peiwei. Analysis and implementation of signal processing method based on EEMD [J]. Modern Electronics Technique, 2011, 34(1):88-90. (in Chinese)
- [6] 单德山,李乔,黄珍. 桥梁动力测试信号的自适应分解与重构[J]. 振动与冲击, 2015, 34(3):1-6.  
Shan Deshan, Li Qiao, Huang Zhen. Signal adaptive decomposition and reconstruction of dynamic testing [J]. Journal of Vibration and Shock, 2015, 34(3):1-6. (in Chinese)
- [7] 周晶. 基于环境振动模态参数识别随机子空间方法与应用[D]. 兰州:兰州理工大学, 2008.
- [8] Peeters B, De Roeck G. Reference based stochastic subspace identification in civil engineering[J]. Inverse Problems in Engineering, 1999, 100(1):1-28.
- [9] 禹丹江,任伟新. 基于经验模式分解的随机子空间识别方法[J]. 地震工程与工程振动, 2005, 25(5):61-66.  
Yu Danjiang, Ren Weixin. Empirical mode decomposition based stochastic subspace identification [J]. Jour-

nal of Earthquake Engineering and Engineering Vibration, 2005, 25(5):61-66. (in Chinese)

- [10] 汤宝平,章国稳,陈卓. 基于谱系聚类的随机子空间模态参数自动识别[J]. 振动与冲击, 2012, 31(10):92-96.  
Tang Baoping, Zhang Guowen, Chen Zhuo. Automatic stochastic subspace identification of modal parameters based on hierarchical clustering method [J]. Journal of Vibration and Shock, 2012, 31(10):92-96. (in Chinese)
- [11] Filippo U, Carmelo G, Annibale L M. Automated modal identification in operational conditions and its application to bridges[J]. Engineering Structures, 2013, 46:264-278.
- [12] 张进林,张榆锋,张燕,等. 经验模态分解端点效应抑制的常用方法比较研究[J]. 云南大学学报:自然科学版, 2010, 32(4):406-412.  
Zhang Jinlin, Zhang Yufeng, Zhang Yan, et al. A comparison of the commonly used methods for the end effect restraint of empirical mode decomposition algorithm [J]. Journal of Yunnan University: Natural Sciences, 2010, 32(4):406-412. (in Chinese)
- [13] 谢沙沙,李素梅,王光华,等. 基于主成分分析和支持向量机的人眼注视识别[J]. 信息技术, 2014(7):163-166.  
Xie Shasha, Li Sumei, Wang Guanghua, et al. The human eye gaze recognition based on main component analyst and support vector machine [J]. Journal of Information and Technology, 2014(7):163-166. (in Chinese)
- [14] 林丽,余轮. 基于相关系数的 EMD 改进算法[J]. 计算机与数字工程, 2008, 36(12):28-29.  
Lin Li, Yu Lun. Improvement on empirical mode decomposition based on correlation coefficient [J]. Computer and Digital Engineering, 2008, 36(12):28-29. (in Chinese)
- [15] 陈仁祥,汤宝平,吕中亮. 基于相关系数的 EEMD 转子振动信号降噪方法[J]. 振动、测试与诊断, 2012, 32(4):542-546.  
Chen Renxiang, Tang Baoping, Lü Zhongliang. Ensemble empirical mode decomposition de-noising method based on correlation coefficients for vibration signal of rotor system [J]. Journal of Vibration, Measurement & Diagnosis, 2012, 32(4):542-546. (in Chinese)



**第一作者简介:**陈永高,男,1984年1月生,副教授。主要研究方向为桥梁健康监测。曾发表《基于 CEEMD 分解和 Data-SSI 算法的斜拉桥模态参数识别》(《振动与冲击》2016年第8期)等论文。  
E-mail: higaoge@163.com