

DOI: 10.11830/ISSN.1000-5013.201606108



DE-ICA 优化算法在工作模态 参数识别的应用

雷宇翔, 缙锦, 王成, 罗伟

(华侨大学 计算机科学与技术学院, 福建 厦门 361021)

摘要: 提出一种差分进化(DE)改进的独立成分分析(ICA)优化算法,解决工作模态参数识别时容易陷入局部最优,难以识别出高阶模态参数的问题.通过对悬臂梁的 ANSYS 仿真数据对比可知:相对于传统的 ICA 方法,结合差分进化算法的 ICA 识别的模态参数精度更高,且能分离出更多的高阶模态,更适合于高阶模态参数的识别.

关键词: 参数识别; 工作模态; 独立成分分析; 差分进化; 随机寻优策略

中图分类号: TP 391 **文献标志码:** A **文章编号:** 1000-5013(2018)02-0286-07

Application of DE-ICA Optimization Algorithm in Operating Modal of Parameter Identification

LEI Yuxiang, GOU Jin, WANG Cheng, LUO Wei

(College of Computer Science and Technology, Huaqiao University, Xiamen 361021, China)

Abstract: An independent solve the problem of the parameter identification in operating model, in which component analysis (ICA) algorithm modified by differential evolution (DE) is proposed. To process the operating modal analysis problem, which is easy to go into local optima and difficult to identify higher order modal parameters. ANSYS simulation result on cantilever shows that, comparing to the traditional ICA, the ICA combined with DE identified the modal parameter is more accurately, and is able to extract more higher-order modal, hence is more suitable for solving higher modal parameter identification.

Keywords: parameter identification; operating modal; independent component analysis; differential evolution; stochastic optimization strategy

自 20 世纪 80 年代末起,人们就开始了对工作模态分析(operational modal analysis, OMA)的研究. Poncelet 等提出利用盲源分离技术进行模态分析的方法,并从数学角度阐述独立成分分析(independent component analysis, ICA)方法^[1-3]和盲源分离(blind source separation, BSS)技术^[4-5]可以用来进行模态分析. 2007 年, Poncelet 等^[6-7]提出用 ICA 方法解决结构工作模态分析问题. Yang 等^[8]将短时傅里叶变换(STFT)应用于 ICA 的预处理阶段,以解决大阻尼结构的模态参数识别问题. ICA 包括目标函数和优化算法^[3, 9-11]两部分. 传统的 ICA 所使用的优化算法容易陷入局部最优,因而在分析连续体模态时,存在鲁棒性低、无法识别出高阶模态等问题^[12]. 差分进化(differential evolution, DE)^[13-14]最早由

收稿日期: 2016-06-02

通信作者: 缙锦(1978-),男,教授,博士,主要从事知识工程的研究. E-mail: goujin@hqu.edu.cn.

基金项目: 国家自然科学基金资助项目(61572204, 51305142); 华侨大学研究生科研创新能力培育计划项目(1511314029)

Storn 和 Price 提出，它以其特有的搜索策略，实现自适应寻优，具有较强的鲁棒性和全局收敛能力，并且通常可以独立于问题的特定信息进行寻优，因而，适用于求解一些常规数学方法无法求解的复杂优化问题，尤其是多峰、病态函数等问题^[13-14]。本文将差分进化算法运用到 ICA 的求解过程中，有效地识别出了连续体结构的高阶模态参数。

1 数学模型

1.1 工作模态参数识别数学模型

在有限元理论中，连续体可以被离散为 N 个自由度的结构振动系统，其在物理坐标下的运动方程可以表示为

$$\mathbf{M}\ddot{\mathbf{x}}(t) + \mathbf{C}\dot{\mathbf{x}}(t) + \mathbf{K}\mathbf{x}(t) = \mathbf{f}(t). \tag{1}$$

式(1)中： \mathbf{M} 为结构的质量矩阵； \mathbf{C} 为结构的阻尼矩阵； \mathbf{K} 为结构的刚度矩阵； $\mathbf{x}(t)$ ， $\dot{\mathbf{x}}(t)$ ， $\ddot{\mathbf{x}}(t)$ 分别为节点的位移、速度和加速度列阵； $\mathbf{f}(t)$ 为节点的载荷列阵。

对于小阻尼的一般振动系统， N 自由度的系统模型的响应可近似表达为

$$\mathbf{x}(t) = \sum_{i=1}^N \boldsymbol{\phi}_i q_i(t) = \boldsymbol{\Phi} \ddot{\mathbf{q}}(t). \tag{2}$$

式(2)中： $\mathbf{x}(t)$ 为系统各节点的响应列阵； $\boldsymbol{\phi}_i$ 为各阶模态振型； $q_i(t)$ 为各阶模态响应。

工作模态参数识别的任务就是仅从观测到的系统的响应 $\mathbf{x}(t)$ 中，分离出一系列模态振型 $q_i(t)$ 、模态频率 ω_i 和模态阻尼比 ξ_i 。

1.2 基于 ICA 模型的工作模态参数识别

ICA 是一种统计方法，目的在于寻求多元数据集的非奇异变换，使变换后各分量之间尽可能相互独立，其数学模型为

$$\mathbf{X}(t) = \mathbf{A}\mathbf{S}(t). \tag{3}$$

式(3)中： $\mathbf{S}(t)$ 为源信号矩阵； \mathbf{A} 为混叠矩阵； $\mathbf{S}(t)$ 经过 \mathbf{A} 的混叠之后，形成矩阵 $\mathbf{X}(t)$ ，即观测到的信号矩阵。

ICA 的任务就是仅通过对观测信号矩阵 $\mathbf{X}(t)$ 进行盲分离，求出分离矩阵 \mathbf{W} ，即

$$\mathbf{Y}(t) = \mathbf{W}\mathbf{X}(t). \tag{4}$$

然后，使分离后的矩阵 $\mathbf{Y}(t)$ 中各个分量 $y_i(t)$ 之间尽可能相互独立。ICA 的判据为独立性，即若分离后的信号之间相互独立，就认为成功实现了信号分离。

对比式(2)和式(3)可以知道：由于模态理论规定结构各阶模态响应相互独立，因此，可以通过 ICA 方法对结构各节点的响应矩阵 $\mathbf{X}(t)$ 进行分离，得出分离矩阵 \mathbf{W} 和各独立成分矩阵 $\mathbf{Y}(t)$ 。其中，各独立成分 $y(t)$ 就是各阶模态坐标响应矩阵 $\mathbf{Q}(t)$ ，可以通过快速傅里叶变换(FFT)和固有时间尺度分解(ITD)获得固有频率 ω 和阻尼比 ξ ^[10]。

1.3 传统 ICA 方法的优化求解算法

文中进行工作模态分析所选取的 ICA 方法为负熵极大化+拟牛顿抽取法，该方法的独立性判据即目标函数为负熵，其统计量近似表达式为

$$J(\mathbf{y}) = [E\{G(\mathbf{y})\} - E\{G(\mathbf{v})\}]^2. \tag{5}$$

式(5)中： \mathbf{v} 为具有零均值且方差与 \mathbf{y} 相同的高斯随机变量； $G(\cdot)$ 为非二次函数。

由式(5)和 $\mathbf{y}_i = \mathbf{w}_i^T \mathbf{X}$ ，以极大化负熵为目标，使用拟牛顿法推导得出分离矩阵分量 \mathbf{w}_i 的迭代公式为

$$\mathbf{w}_i = E\{\mathbf{X}G(\mathbf{X}^T \mathbf{w}_i)\} - E\{G'(\mathbf{w}_i^T \mathbf{X})\} \mathbf{w}_i. \tag{6}$$

每次迭代后，对 \mathbf{w}_i 进行正交归一化处理，则有

$$\mathbf{w}_i = \mathbf{w}_i - \mathbf{W}\mathbf{W}^T \mathbf{w}_i, \quad \mathbf{w}_i = \mathbf{w}_i / \|\mathbf{w}_i\|. \tag{7}$$

算法的收敛准则：迭代前的 \mathbf{w}_i 和迭代后的 \mathbf{w}_i 指向同一个方向，即它们的内积接近于 1。

拟牛顿抽取法具有收敛速度快，精度较高等优点，但由于其确定性的求解过程，因而，容易陷入局部最优，难以适应多峰问题。在应对多模态分离的问题时，拟牛顿抽取法往往只能分离出少数几个模态，难以获得高阶模态参数^[15-16]。

2 利用差分进化的 ICA 进行工作模态参数识别

差分进化^[9,16]从某个随机生成的初始种群开始,对种群的个体进行交叉、变异,留下适应度较高的个体作为子代,不断循环,向全局最优解逼近,主要包含初始化、变异、交叉、选择等 4 个步骤.

利用差分进化的 ICA 工作模态参数识别算法流程,如图 1 所示.

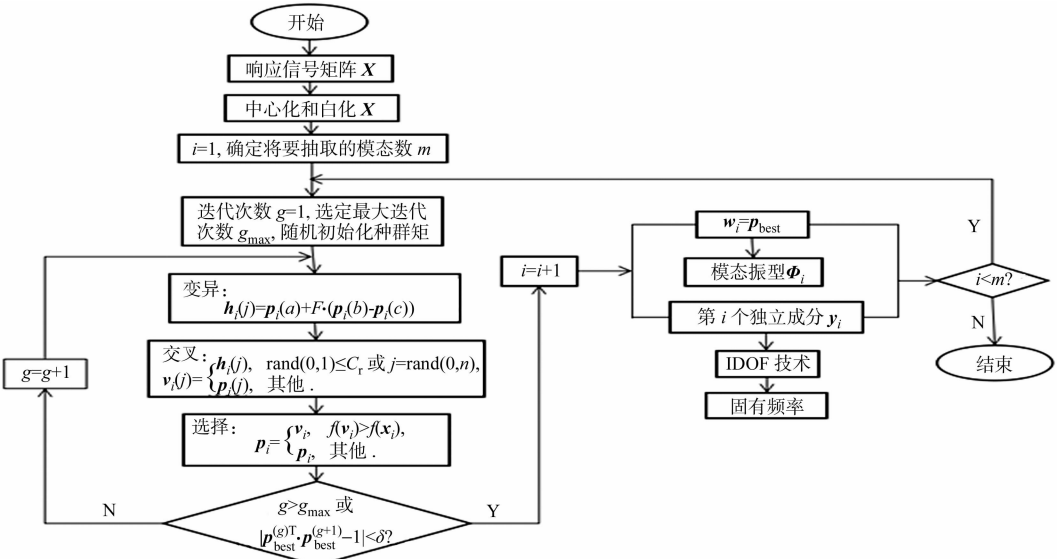


图 1 利用差分进化的 ICA 工作模态参数识别的流程

Fig. 1 Flow diagram of ICA utilizing DE for operational modal parameter identification

利用基于差分进化的 ICA 进行工作模态参数识别,就是将差分进化作为工作模态参数识别的优化算法,即用差分进化代替传统的线性回归法.核心是对分离矩阵 W 进行寻优,依次抽取出 W 中的每个分量,即每一模态对应的振型.因此,只需修改差分进化模型的某些步骤执行方法,并赋予其中的参数相应的物理意义即可.差分进化改进的传统独立成分分析(ICA)优化算法有如下 4 个主要步骤.

步骤 1 确定将要抽取的模态数 m 、结构有限元模型的节点数 n 、响应数据的采集点数 t ,以及结构的响应矩阵 X ,则有 $Y_{m \times t} = W_{m \times n} \cdot X_{n \times t}$.

步骤 2 对差分进化算法的步骤进行相应调整.由于需要对 $w_i (i=1,2,\cdots,m)$ 进行逐个抽取,所以,种群中的每个个体为一个 $1 \times n$ 的列向量,存放在种群矩阵 P 中,即 $P = (p_1, p_2, \cdots, p_i, \cdots, p_{NP})^T$. 其中: $p_i = (p_i(1), p_i(2), \cdots, p_i(j), \cdots, p_i(n))^T, j=1,2,\cdots,n; i=1,2,\cdots,NP$.

步骤 3 将种群 P 中的所有个体 p_i 按照式(7)作正交归一化处理后,投入差分进化算法的主循环中,并用负熵作为适应度函数,即 $J(y_i) = [E\{G(y_i)\} - E\{G(v)\}]^2, y_i = p_i^T X$. 所得的子代的每个个体同样按照式(7)作正交归一化处理.算法的收敛条件:当 $|p_{best}^{(g)T} \cdot p_{best}^{(g+1)} - 1| < 10^{-9}$ 时,或超过最大迭代次数(5 000 次)后,认为算法收敛;而当满足此收敛条件后,获得近似最优解 p_{best} .令 $w_i = p_{best}$,完成当前分量 w_i 的抽取.

步骤 4 $i=i+1$,返回步骤 2,继续抽取 W 的下一个分量,直到 $i>m$,即全部分量抽取完毕.

3 仿真验证结果与分析

3.1 仿真参数

通过悬臂梁(图 2)在白噪声环境激励下的振动响应仿真数据验证方法的可行性,并对比传统 ICA 和利用差分进化的 ICA 的工作模态参数识别性能.

该悬臂梁材质为标准钢材,仿真环境温度为常温(20 ℃),把梁作 40 等分,外部激励施加在其末端.具体参数如下:悬臂梁尺寸(长×宽×高)为 1.00 m×0.02 m×0.02 m;横截面积为 $4 \times 10^{-4} \text{ m}^2$;密度为 $7\,860 \text{ kg} \cdot \text{m}^{-3}$;惯性矩为 $WH^3/12$;杨氏模量为 0.21 TPa.对悬臂梁末端施加高斯白噪声激励,时长为




图 2 悬臂梁的有限元模型

Fig. 2 Finite element model of cantilever

5 s. 采用 ANSYS 软件 14.0 版本, 采样频率为 10 kHz, 采样时长为 4.5 s, 并舍弃起振阶段的前 0.5 s.

仿真环境描述: 传统 ICA 和利用差分进化的 ICA 仿真均在同一台计算机上进行. 计算机配置: 操作系统为 Windows 7.0×64; 处理器为 Intel® Core™ i3-3220 CPU @ 3.30 GHz (4CPUs); 内存为 8 192 MB RAM; 实现语言为 Matlab 2015a.

以负熵为优化目标, $G(\cdot)$ 是非二次函数, $G_2(\mathbf{y}) = -\exp(-\mathbf{y}^2/2)$. 差分进化的参数设置: 个体数 80; 最大迭代次数 4 000; 每次循环随机变换 F (比例因子) 与 C_r (交叉概率) 的值. 拟牛顿法的参数设置: 最大迭代次数 4 000. 两种方法采用统一收敛准则: 当前循环获得的最优解 $\mathbf{w}_i^{(1)}$ (正交归一化) 与上一循环获得的最优解 $\mathbf{w}_i^{(0)}$ (正交归一化) 指向同一个方向. 即当它们的内积与 1 的差的绝对值小于 10^{-9} 时, 认为算法收敛. 分别用传统 ICA 和利用差分进化的 ICA (DE-ICA) 进行 10 次试验后, 记录并分别取其 MAC 值最高的结果和耗时.

3.2 模态振型的 MAC 值评价指标

在比较高维空间中两个向量的相似程度时, 一个较常使用的指标是 MAC 值, 即余弦距离的平方. 向量 \mathbf{w}_i 和向量 $\boldsymbol{\phi}_i$ 的 MAC 值为

$$\text{MAC}(\mathbf{w}_i, \boldsymbol{\phi}_i) = (\mathbf{w}_i^T \boldsymbol{\phi}_i)^2 / [\mathbf{w}_i^T \mathbf{w}_i \cdot \boldsymbol{\phi}_i^T \boldsymbol{\phi}_i]. \tag{8}$$

由式(8)可知: $0 \leq \text{MAC} \leq 1$, MAC 值越高, 表明两个向量近似程度越高. 因此, 可以通过求出 ICA 分离矩阵中的分量 \mathbf{w}_i 与 ANSYS 仿真的模态振型 $\boldsymbol{\phi}_i$, 验证 ICA 模态抽取的精度.

3.3 仿真结果与分析

通过悬臂梁的响应矩阵 $\mathbf{X}(t)$, 并利用式(4)求出该响应矩阵的独立成分 $\mathbf{Y}(t)$ 和分离矩阵 \mathbf{W} . 每个独立成分 $\mathbf{Y}(t)$ 表示悬臂梁的一个模态, 利用 FFT 变换, 将数据从时域投射到频率域上, 其峰值最高点的横坐标就反映了该模态的模态频率; 每个 \mathbf{W} 的分量对应一个模态振型.

将传统 ICA 与利用差分进化的 ICA 求解出的独立成分 $\mathbf{Y}(t)$ 进行 FFT 变换的结果, 如图 3, 4 所示. 图 3, 4 中: 纵坐标最高点对应的横坐标就是识别出的模态频率. 模态频率的对比结果, 如表 1 所示. 表 1

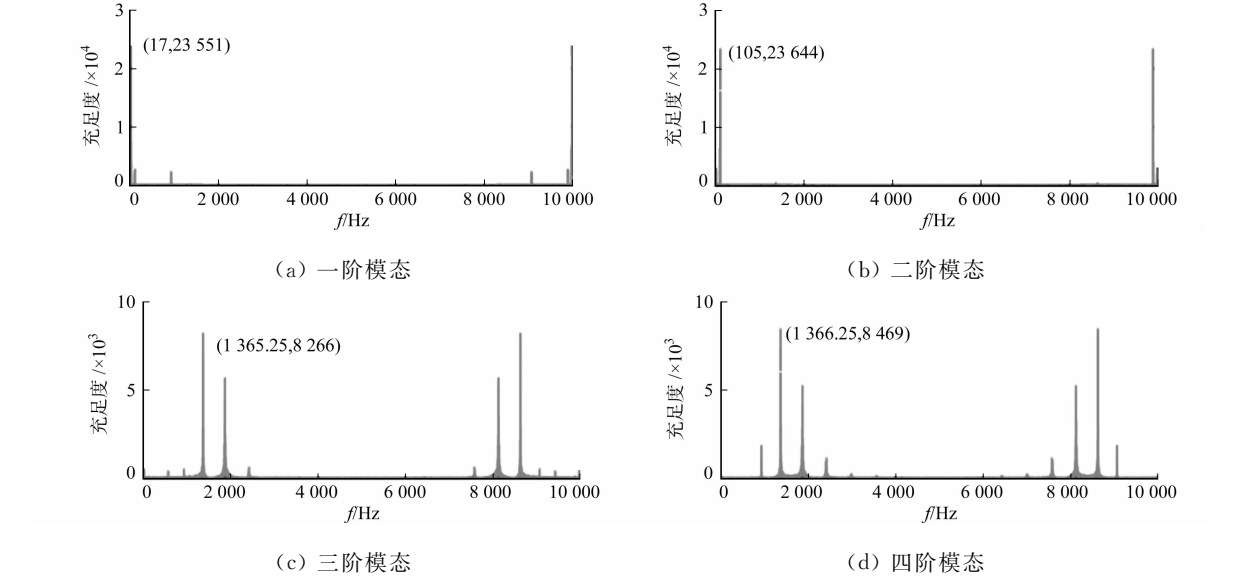



图 3 差分进化 ICA 算法识别出的独立成分 FFT 变换结果

Fig. 3 FFT results of independent components identified by differential evolution ICA algorithm






图 4 传统 ICA 算法识别出的独立成分 FFT 变换结果

Fig. 4 FFT results of independent components identified on traditional based ICA algorithm

中: f_{re} 表示真实模态频率; f_{ICA} 表示传统 ICA 识别频率; f_{DE-ICA} 表示差分进化的 ICA 算法识别频率.

利用差分进化的 ICA(DE-ICA)算法求解出的分离矩阵分量 w_i ,如图 5 所示.将传统 ICA 与 DE-ICA 进行模态振型识别的结果与仿真数据对比,绘图并求出 MAC 值,分别如图 6,7 和表 2 所示.

两种 ICA 算法分别重复 10 次,耗时如表 3 所示.由表 3 可以看出:差分进化 ICA 用时最短为 671 s,最长为 1 129 s,平均用时为 829 s,而传统 ICA 的平均用时仅为 8.274 s.

表 1 不同 ICA 方法识别的模态频率对比

表 2 不同 ICA 方法识别模态振型 MAC 值的对比

Tab.1 Comparison of identified modal frequency in different ICAs

Tab.2 Comparison of MACs of identified modal shapes in different ICAs

真实模态阶数	f_{re}	f_{ICA}	f_{DE-ICA}
1	16.694	17.00	17.00
2	104.425	105.00	104.75
3	291.509	—	291.75
4	568.747	—	567.50


有限元模态阶数	传统 ICA 识别		DE-ICA 识别	
	阶数	K_{MAC}	独立成分	K_{MAC}
1	1	0.801 4	6	0.875 2
2	2	0.841 1	2	0.887 0
3	—	—	1	0.850 4
4	—	—	4	0.876 0

表 3 两种不同 ICA 方法用时对比

Tab.3 Comparison of time consumed by two different ICAs

算法	1	2	3	4	5	6	7	8	9	10	平均值
DE-ICA 算法	868.616	684.751	978.890	1 128.982	675.633	867.778	749.158	836.853	830.844	670.686	829.219
传统 ICA 算法	8.390	10.590	6.474	7.604	6.634	8.504	11.625	6.730	8.734	7.454	8.274

1) 由图 3,4,6,7 和表 1,2 可以看出:利用差分进化的 ICA 方法能有效识别出前 4 阶模态频率,而传统 ICA 方法只能识别出前 2 阶模态频率.传统的 ICA 方法只分离出前 2 个模态振型,而利用差分进化的 ICA 方法分离出了前 4 个模态振型.由表 2 可以看出:两种方法在识别模态振型时,均存在误差,但利用差分进化的 ICA 精度略高于传统 ICA.



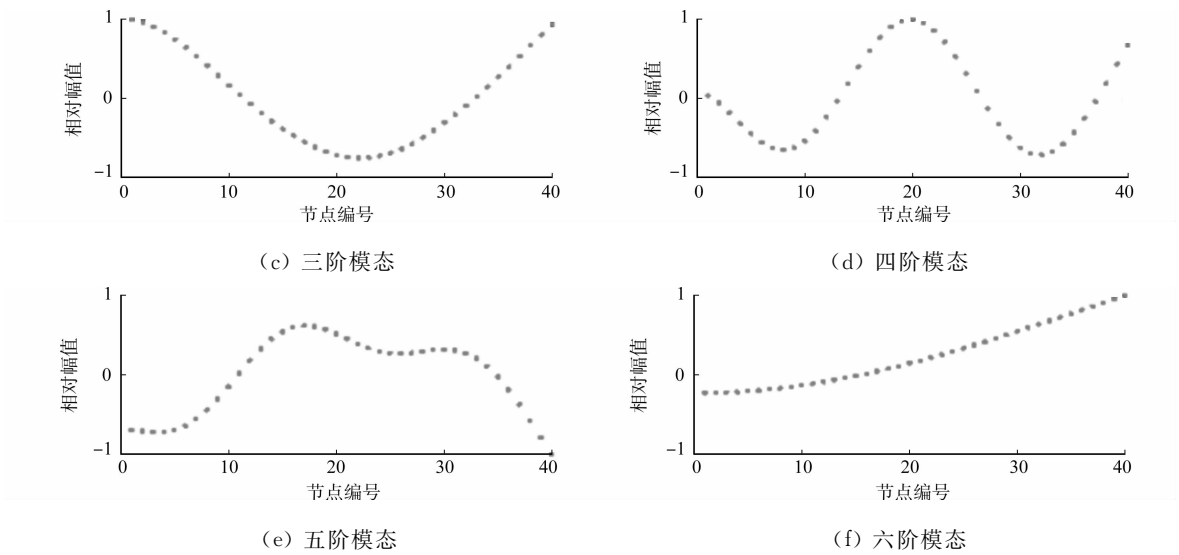


图 5 差分进化 ICA 算法的模态抽取结果

Fig. 5 Modal extraction of differential evolution based ICA algorithm




图 6 传统 ICA 算法识别出的模态振型

Fig. 6 Modal shapes identified on traditional based ICA algorithm

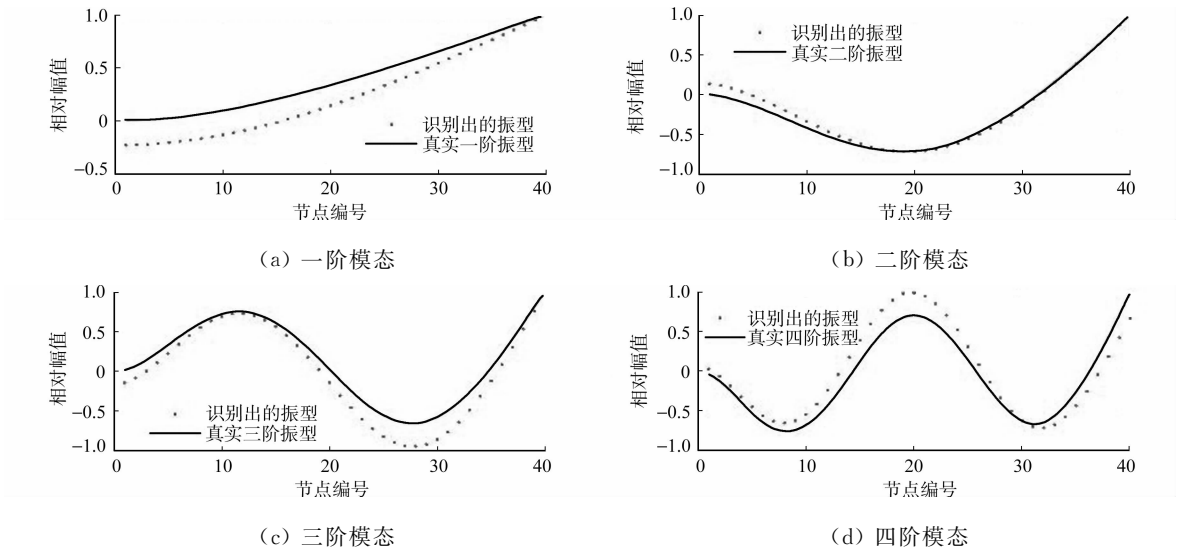


图 7 差分进化 ICA 算法识别出的模态振型

Fig. 7 Modal shapes identified by differential evolution ICA algorithm

2) 由图 4、5 的第 3、5 子图可知:差分进化 ICA 分离出的第 3、第 5 独立成分未对应任何模态,并且图 4 中的第 3、第 5 分量的主峰横坐标数值未对应任何模态频率值。

3) 由表 3 可以看出:利用差分进化的 ICA 方法耗时较多,并且耗时长短相差幅度较大. 针对模态频率和振型的识别误差,初步判断可能原因可能是:FFT 变换的分辨率为 0.25 Hz,且变换过程存在精度问题和泄漏现象;ICA 及 DE 本身的误差;模态分离的结果中存在虚假模态,利用差分进化的 ICA 方法未能成功将其分离。

4 结束语

针对利用传统 ICA 方法进行工作模态参数识别容易陷入局部最优,难以识别出高阶模态参数的问题,提出一种利用差分进化求解 ICA 的新方法.通过对悬臂梁的 ANSYS 仿真数据进行对比,验证结果表明,所提出的新方法能够有效识别出简支梁模型的高阶模态参数.由于使用了差分进化,算法的时间复杂度较高,模态分离的结果中存在虚假模态.如何降低算法复杂度,避免识别虚假模态,并将方法运用到更加复杂的工程结构中,是进一步的研究方向.

参考文献:

- [1] HERAULT J, JUTTEN C. Space or time adaptive signal processing by neural network models[C]//Neural Networks for Computing. [S. l.]: AIP Publishing, 1986, 151(1): 206-211. DOI:10.1063/1.36258.
- [2] JUTTEN C, HERAULT J. Blind separation of sources, part I: An adaptive algorithm based on neuromimetic architecture[J]. Signal Processing, 1991, 24(1): 1-10. DOI:10.1016/0165-1684(91)90079-X.
- [3] CHOI S. Independent component analysis[M]//Encyclopedia of Biometrics. London: Springer, 2015: 917-924.
- [4] HAYKIN S, CHEN Zhe. The cocktail party problem[J]. Neural Computation, 2005, 17(9): 1875-1902. DOI:10.1162/0899766054322964.
- [5] BRONKHORST A W. The cocktail-party problem revisited: Early processing and selection of multi-talker speech [J]. Attention, Perception, and Psychophysics, 2015, 77(5): 1465-1487. DOI:10.3758/s13414-015-0882-9.
- [6] KERSCHEN G, PONCELET F, GOLINVAL J C. Physical interpretation of independent component analysis in structural dynamics[J]. Mechanical Systems and Signal Processing, 2007, 21(4): 1561-1575. DOI:10.1016/j.ymssp.2006.07.009.
- [7] PONCELET F, KERSCHEN G, GOLINVAL J C, *et al.* Output-only modal analysis using blind source separation techniques[J]. Mechanical Systems and Signal Processing, 2007, 21(6): 2335-2358. DOI:10.1016/j.ymssp.2006.12.005.
- [8] YANG Yongchao, NAGARAJAIAH S. Time-frequency blind source separation using independent component analysis for output-only modal identification of highly damped structures[J]. Journal of Structural Engineering, 2012, 139(10): 1780-1793. DOI:10.1061/(ASCE)ST.1943-541X.0000621.
- [9] BELL A J, SEJNOWSKI T J. An information-maximization approach to blind separation and blind deconvolution [J]. Neural Computation, 1995, 7(6): 1129-1159. DOI:10.1162/neco.1995.7.6.1129.
- [10] KARHUNEN J, OJA E, WANG Liuyue, *et al.* A class of neural networks for independent component analysis[J]. IEEE Transactions on Neural Networks, 1997, 8(3): 486-504. DOI:10.1109/72.572090.
- [11] DU K L, SWAMY M N S. Independent component analysis[M]//Neural Networks and Statistical Learning. New York: Springer, 2014: 419-450.
- [12] COMON P, JUTTEN C, HERAULT J. Blind separation of sources, part II: Problems statement[J]. Signal Processing, 1991, 24(1): 11-20. DOI:10.1016/0165-1684(91)90080-3.
- [13] STORN R, PRICE K. Differential evolution—a simple and efficient heuristic for global optimization over continuous spaces[J]. Journal of Global Optimization, 1997, 11(4): 341-359.
- [14] CIVICIOGLU P, BESDOK E. A conceptual comparison of the Cuckoo-search, particle swarm optimization, differential evolution and artificial bee colony algorithms[J]. Artificial Intelligence Review, 2013, 39(4): 315-346. DOI:10.1007/s10462-011-9276-0.
- [15] CICHOCKI A, AMARI S, CAO Jiangting. Neural network models for blind separation of time delayed and convolved signals[J]. IEICE Transactions on Fundamentals of Electronics, Communications and Computer Sciences, 1997, 80(9): 1595-1603.
- [16] 魏文红, 秦勇. 采用多目标差分进化的移动 Ad Hoc 网络节能路由算法[J]. 华侨大学学报(自然科学版), 2016, 37(5): 654-658. DOI:10.11830/ISSN.1000-5013.201605026.

(责任编辑: 黄晓楠 英文审校: 吴逢铁)