

基于智能算法的稳定点自动分析方法研究*

张超¹, 邓扬¹, 李爱群^{1,2}, 周泰翔¹, 李雨航², 钟国强³

(1. 北京建筑大学土木与交通工程学院 北京, 100044)

(2. 东南大学土木工程学院 南京, 210096)

(3. 山东省交通规划设计院集团有限公司 济南, 250101)

摘要 为了提高辨识稳定图中真实模态的准确性与自动化程度,首先,从稳定点定义方式的角度论述了聚类算法效果欠佳的原因,并采用异阶系统非等权重的定义方式输出稳定点;其次,基于数据挖掘思想,采用改进的辨识聚类结构的有序点(ordering points to identify the clustering structure,简称 OPTICS)算法自动清洗稳定点集,通过遍历性搜索的方式确定输入参数;然后,提出结合度矩阵去噪的自适应局部密度谱聚类(local density adaptive spectral clustering,简称 SC-DA)算法分析稳定点集,并以簇中值作为模态参数的代表值,实现模态参数的自动化识别;最后,将含有密集模态的外滩大桥作为识别对象进行试验验证。试验结果表明:所提出方法具有较高的精度,与频域分解(frequency domain decomposition,简称 FDD)法的频率结果最大相差仅为 0.012 3 Hz,且在线识别的准确率达到 82.86%,显著高于基于层次聚类的自动识别方法,实现了无人工干预下模态参数的自动、准确识别,具有一定的工程应用前景。

关键词 模态参数识别;自动化;聚类分析;辨识聚类结构的有序点算法;自适应局部密度谱聚类算法;随机子空间法;稳定图

中图分类号 U441.3;TB123;TH17

引言

模态参数识别是结构健康监测的重要内容^[1]。运行模态分析(operational modal analysis,简称 OMA)由于无需人工激励且操作简单,近年来受到了广泛的关注。其中,随机子空间识别法(stochastic subspace identification,简称 SSI)因具有较高的精度及稳定性^[2],已成为目前 OMA 中最有效的识别算法之一。

工程实践中,SSI 难以根据可观矩阵的奇异值突变来判定系统阶次进而识别模态参数^[3]。文献[4]提出了基于假设系统阶次的稳定图法,即通过稳定点自发形成的稳定轴辨识模态;然而由于系统阶次的过估计与噪声影响,稳定图不可避免地引入虚假极点,导致人工辨识模态遭受严重干扰,识别结果主观性强。为此,对稳定图法的研究主要集中在 2 个方面^[5-6]:①通过各类模态验证准则提纯稳定点集;②借助聚类算法分析稳定点集实现模态参数的自动识别。因此,纯净的稳定点集是准确识别模态

参数的基础,然而各类准则均有一定的适用范围^[7],且众多的阈值将增加人工干预的难度与成本。此外,聚类算法众多,选择一种适合于稳定点数据结构的聚类算法十分必要。目前,多数研究采用的算法均以距离为分类统计量,仅能发现圆形形状的簇^[8],效果受限,难以保证结果的准确性。

针对上述问题,首先,笔者从稳定点定义方式的角度论述了聚类分析难以取得良好效果的原因,采用异阶系统非等权重的定义方式输出稳定点;其次,基于稳定点集自身的统计特征,采用 OPTICS 改进算法自动去除虚假极点,通过遍历性搜索的方式确定输入参数;然后,提出一种基于度矩阵的去噪方法,并结合 SC-DA 算法自动分析稳定点集;最后,利用外滩大桥监测数据验证了所提出方法的有效性,并结合识别结果证明了模态相位共线性(modal phase collinearity,简称 MPC)和平均相位偏差(mean phase deviation,简称 MPD)在软硬标准中的局限性。

* 国家自然科学基金资助项目(51878027);北京市教委青年拔尖人才培养计划资助项目(CIT&TCD201904060);北京建筑大学基本科研业务费资助项目(X20174, X21073);北京市博士后经费资助项目(2021-ZZ-105)

收稿日期:2022-11-27;修回日期:2023-02-23

1 模态参数识别

1.1 随机子空间法

笔者选择协方差驱动的随机子空间识别法(covariance driven stochastic subspace identification, 简称 COV-SSI)识别模态参数。相比于数据驱动的随机子空间法, COV-SSI 运行速度更快, 占用内存更少^[9], 更利于在线分析。COV-SSI 的原理及实现步骤可参考相关文献, 笔者不在赘述。由于 Toeplitz 方阵的行块数 b 直接影响 COV-SSI 的输出精度与计算量^[10], 对此笔者采用文献[11]的方法, 取 $b \geq 0.5(f_s / f_0)$, 其中: f_s 为采样频率; f_0 为结构基频。尽管 b 的取值越大越好^[12], 但在实际应用中为避免计算成本过高, 在 f_0 保守估计的基础上, b 取值等于或稍大于计算值即可。

1.2 数值模型

笔者采用 ANSYS APDL 软件建立了一个跨度为 20 m 的简支梁模型。该模型的单元类型为 BEAM189, 沿长度方向的单元尺寸为 1 m, 弹性模量为 3×10^{10} Pa, 密度为 2.36×10^3 kg/m³, 主泊松比为 0.15。图 1 为简支梁模型截面示意图。

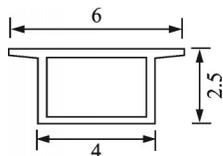


图1 简支梁模型截面示意图(单位: m)

Fig.1 Sectional drawing (unit: m)

简支梁模型的激励与测点位置如图 2 所示。为模拟自然激励条件, 采用多输入多输出的形式进行试验模态分析, 激励采用时长为 5 min 的高斯白噪声, 采样频率为 200 Hz。经过完全法的瞬态动力分析后, 得到相关节点位置的加速度响应信号。

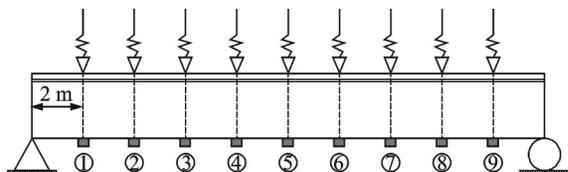


图2 简支梁模型的激励与测点位置

Fig.2 The excitation and measurement points in simple supported beam model

1.3 稳定点提取

稳定点的有效提取是准确识别模态的前提。然

而, 传统稳定点定义方式, 即比较邻阶系统极点, 实际上是默认了各阶系统的等权关系, 导致高阶系统的极点凭借其自身的数量优势在输出结果上占比更大。事实上, 高阶系统极点的可靠性不如低阶系统极点^[13], 即理论上低阶系统应被赋予更高的权重。这种系统非等权重关系的思想在实际工作中是隐含的(根据经验, 仅存于高阶系统的稳定轴将不被视为真实模态)。在自动识别方面, 权重关系将决定稳定点集的质量, 直接影响聚类算法的效果。例如, 在等权关系下高阶系统极点更多, 意味着包含的虚假极点更多, 模态对应的簇稀疏性更强, 聚类分析效果不佳。因此, 默认各阶系统等权关系的传统定义方式将产生潜在的数据缺陷, 不利于聚类分析。

忽视各阶系统的权重关系, 导致构造出的稳定点集可靠度不高, 是聚类算法难以取得良好分析效果的根本原因之一。对此, 笔者采用异阶系统非等权重的稳定点定义方式^[14], 将高于某阶系统的极点均与该阶系统的极点进行比较。该方式构造出的极点集具有低阶多、高阶少的分布特点, 故输出的极点集更加可靠。将该定义方式结合稳定判别标准, 筛选出稳定极点: $d(f_u, f_v)$, $d(\xi_u, \xi_v)$ 分别为第 u, v 阶模态的频率差值和阻尼比差值, 取值分别为 0.01 和 0.04; $MAC(\varphi_u, \varphi_v)$ 为第 u, v 阶模态的振型相关系数, 取值为 0.995。具体计算过程见文献[7]。利用上述方法分析简支梁的响应信号, 稳定点提取结果如图 3 所示。

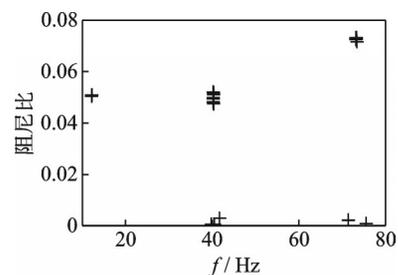


图3 稳定点提取结果

Fig.3 Results of stable poles extracted

1.4 稳定点集清洗

尽管稳定判别标准可在一定程度上滤除虚假极点, 但该方法效果有限。根据数据统计特征, 相比于真实极点(正常点), 虚假极点(异常点)发生频率较低, 即在数据空间中, 异常点占据低密度区域, 正常点占据高密度区域。对此, 笔者采用改进的 OPTICS 算法^[14]对稳定点集进行处理, 主要步骤如下: ①创建以数据点处理次序为横坐标、可达距离为纵

坐标的可达距离图;②通过寻找各陡降区和陡升区构成的凹陷处发现正常点。

由于OPTICS的输出是层次结构,即各级密度的簇会发生嵌套行为,改进版本仅提取最底层的高密度簇,可极大提高异常点被去除的概率。

为进一步保证OPTICS去噪效果的稳定性,采用遍历性搜寻的方式获取输入参数 N_{\minpts} 最优值,并定义评价函数DT为

$$DT = \frac{\sum_{p=1}^c \sum_{q=1}^{n_p} |d_{pq} - \mu_p|^2}{\sum_{p=1}^c n_p} \quad (1)$$

其中: d_{pq} 为第 p 个簇内第 q 个样本点间距; μ_p 为第 p 个簇内样本点间距的均值; n_p 为第 p 个簇包含样本点间距的个数; c 为簇的个数。

式(1)本质上是各簇内样本点间距的离散程度的平均水平。异常点去除越彻底,DT值越小,故利用最小值可寻找最佳 N_{\minpts} 。 N_{\minpts} 表示簇至少包含的点数阈值,当值过小时,可能会将由少量异常点构成的虚假簇误判为真实簇;当值过大时,可能会将孤立的异常点包含到真实簇中。因此,将搜索区间取为 $[N_{\max}, 4N_{\max}]$, N_{\max} 为最大假设系统阶数。利用上述方法分析图3中的稳定点集, N_{\minpts} 的寻优结果为100。OPTICS分析结果如图4所示。结果表明,该算法可显著去除虚假极点。

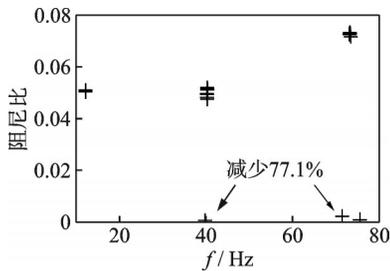


图4 OPTICS分析结果

Fig.4 Results output by OPTICS

2 自动化识别

2.1 SC-DA算法

清洗稳定点集后,需要利用聚类算法实现模式识别的自动化功能。传统算法(K-means、层次聚类算法等)仅能发现凸形簇,且效果受孤立点影响较大。对此,笔者引入SC-DA^[15]算法,该算法是谱聚类算法(spectral clustering,简称SC)的一种,易于实现,效果优于传统聚类算法^[16]。

由于邻接矩阵的优劣直接决定谱聚类效果^[17],

因而样本点间的相似性度量方式十分重要。事实上,样本点是否相似不仅由空间距离决定,还取决于是否处在同一密度区域。SC-DA算法通过共同邻点的方式考虑两点间密度的一致性,这种度量方式更符合实际,可有效放大同簇、异簇样本点间的相似度和相异度。相比于经典谱聚类算法(即Ng-Jordan-Weiss,简称NJW)与自调节谱聚类算法(self-tuning spectral clustering,简称SC-ST),SC-DA算法具有更好的效果^[18],其计算式为

$$S_L(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2(\text{CNN}(x_i, x_j) + 1)}\right) \quad (2)$$

其中: σ 为核宽度,为所有样本点间距的前10%~20%的均值; $\text{CNN}(x_i, x_j)$ 为样本点 x_i 和 x_j 的 ϵ 邻域的交集内样本点的个数; ϵ 为10倍的各样本点与其最近点间距的均值。

一个好的相似度函数可使邻接矩阵尽可能地沿对角线成块状分布^[18]。为了验证SC-DA算法的优势,将图4中的稳定点集分别应用NJW,SC-ST和SC-DA算法计算邻接矩阵,并采用灰度图像的形式输出。邻接矩阵的灰度图像如图5所示。可以看出,SC-DA算法的计算结果接近理想状态,对应于3个簇的矩形块沿对角线高亮分布,显著优于NJW和SC-ST算法的计算结果。

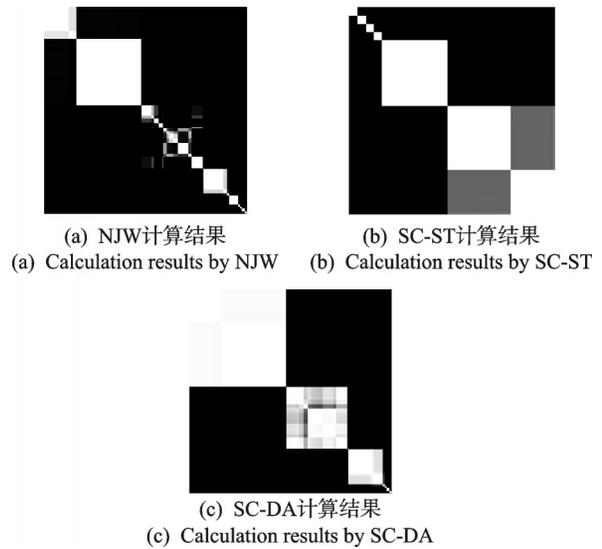


图5 邻接矩阵的灰度图像

Fig.5 Grayscale images of affinity matrices

SC-DA算法的主要步骤如下:

- 1) 由 S_L 构建邻接矩阵 $W \in R^{n \times n}$,即 $W(i, j) = S_L(x_i, x_j)$,其中, $i, j \in [1, n]$, n 为样本点数;
- 2) 根据 W 计算度矩阵 $D \in R^{n \times n}$,即 $D(i, i) = \sum_{j=1}^n W(i, j)$,其余元素为0;

- 3) 利用 W 和 D 构造对称正则化的拉普拉斯矩阵, 即 $L_{\text{sym}} = D^{-\frac{1}{2}}(D - W)D^{-\frac{1}{2}}$;
- 4) 根据 L_{sym} 的最大特征值间隙确定 k 值;
- 5) 计算 L_{sym} 前 k 个特征向量并存于矩阵 $U \in R^{n \times k}$ 中;
- 6) 将 U 按行进行标准化得到 H , 即 $H(i, j) = U(i, j) / \left(\sum_{j=1}^n U(i, j)^2 \right)^{\frac{1}{2}}$;

7) 将 H 的每一行视作一个 k 维样本点, 用 k -means 算法将该样本点集聚类成 k 个簇。

通过观察, 步骤 2 的度矩阵可拆分为

$$D(i, i) = \sum_{j=1}^{n_{1,i}} W_1(i, j) + \sum_{j=1}^{n_{2,i}} W_2(i, j) \quad (3)$$

其中: $n_{1,i}, n_{2,i}$ 分别为与 x_i 同簇、异簇的样本点数; $W_1(i, j)$, $W_2(i, j)$ 分别为与 x_i 同簇、异簇的邻阶矩阵元素。

由于 $W_2(i, j)$ 接近 0, 故式(3)可简化为

$$D(i, i) \approx \sum_{j=1}^{n_{1,i}} W_1(i, j) \quad (4)$$

由式(4)可以看出, $D(i, i)$ 主要与 x_i 所属的簇规模 $n_{1,i}$ 以及 x_i 与同簇点的邻接关系 $W_1(i, j)$ 相关, 规模越大, 关系越强, 则 $D(i, i)$ 值越大, 反之则越小。正常点所属的簇具有致密性, 符合规模大、关系强的特征, $D(i, i)$ 值应很大。由于异常点不属于任何簇或属于稀疏簇, 其规模小、关系弱, 因此 $D(i, i)$ 值应很小。根据该特征, 笔者提出一种基于度矩阵的去噪方法, 其核心思想为: 由于 OPTICS 默认成簇的样本点规模应大于等于 N_{minpts} , 且 $W_1(i, j)$ 接近 1, 故真实极点的 $D(i, i)$ 应不小于 $1 \times N_{\text{minpts}}$ 。由于 SC-DA 的相似度量方式的优势, 未被剔除的虚假极点或虚假极点簇在 W 中会被进一步分离出来(如图 5(c)右下角所示), 导致簇规模缩减, 因此笔者保守假设最大缩减量为 $1/3 N_{\text{minpts}}$, 即真实极点的 $D(i, i)$ 值不应小于 $1 \times (2/3 N_{\text{minpts}})$, 否则将被视为异常点剔除。将该方法置于步骤 3 之前, 进一步降低噪声对识别的干扰。

将上述算法用于图 4 中的稳定点集, L_{sym} 矩阵的特征值如图 6 所示。最大特征值间隙位于第 3, 4 个特征值之间, 准确得到簇个数 $k=3$ 。SC-DA 聚类结果如图 7 所示。可见, 虚假极点已被彻底去除, 数据集被准确地聚类为 3 个簇, 分别对应 3 个模态。

2.2 模态参数拾取办法

聚类分析后需拾取各簇中心作为模态参数代表值。为应对虚假极点未被剔除彻底的可能情况, 笔者以簇中值的方式拾取模态参数, 该方式可在一定

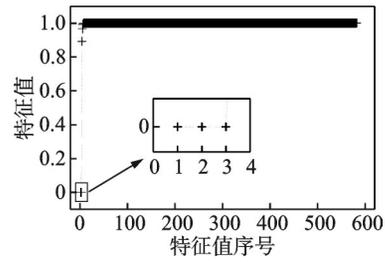


图 6 L_{sym} 矩阵的特征值

Fig.6 Eigenvalues of L_{sym} matrix

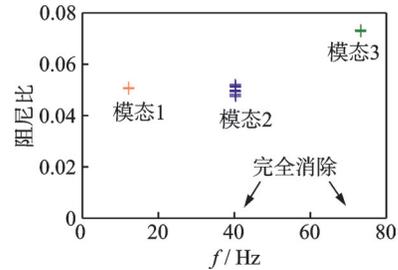


图 7 SC-DA 聚类结果

Fig.7 Results output by SC-DA

程度上降低簇内离群点对参数拾取的干扰^[2]。简支梁模型识别结果如表 1 所示。

表 1 简支梁模型识别结果

Tab.1 Identification results of the supported girder

参数	阶次	理论值	测试值	误差/%
f/Hz	1	12.184	12.189	0.041
	2	40.289	40.279	0.025
	3	73.753	73.273	0.651
阻尼比	1	0.05	0.050 4	0.800
	2	0.05	0.051 1	2.200
	3	0.076 6	0.072 8	4.961

2.3 模态参数自动化识别

模态参数自动化识别流程如图 8 所示。

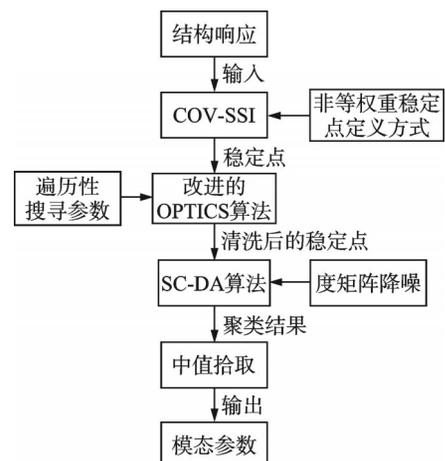


图 8 模态参数自动化识别流程

Fig.8 Automatic identification process of modal parameters

3 桥梁模态识别算例

3.1 桥梁概况

宁波外滩大桥横跨甬江,位于江北区和鄞州区之间,外滩大桥与传感器布置图如图 9 所示。主桥

采用独塔四索面异型斜拉桥结构,全钢结构,跨径布置自西向东为 225 m+82 m+30 m,全长为 337 m。主梁采用分离式钢箱梁,通过横梁连为整体。索塔采用三角形斜塔结构,向江东侧倾斜,位于主梁中间,前塔柱从塔头分出两支倾斜向下延伸,在桥面处与主梁固结,通过主梁后竖直向下与主墩固结。

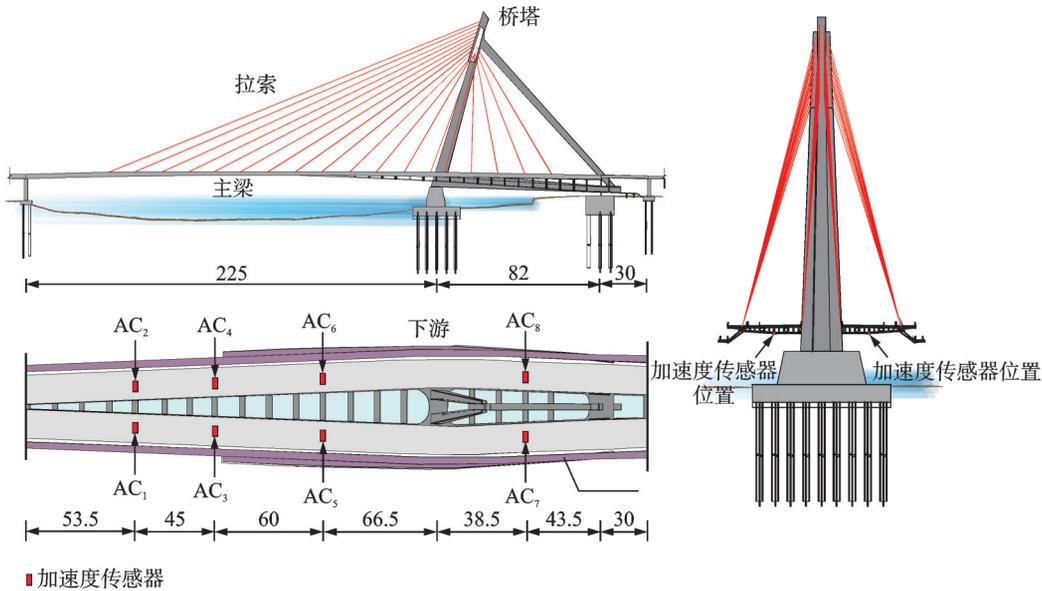


图 9 外滩大桥与传感器布置图(单位: m)

Fig.9 Layout of Waitan Bridge and accelerometers (unit: m)

3.2 模态识别

本次分析采用 2020 年 6 月 4 日 12 时前 10 min 的加速度响应记录,采样频率为 50 Hz,截止频率设为 3 Hz。因为 FDD 的频率识别精度高,且具有密频分辨能力,故采用该方法手动分析结构的模态频率。图 10 为 FDD 的识别结果。1 阶奇异值谱共 10 个显著峰值,分别代表 10 阶不同模态。

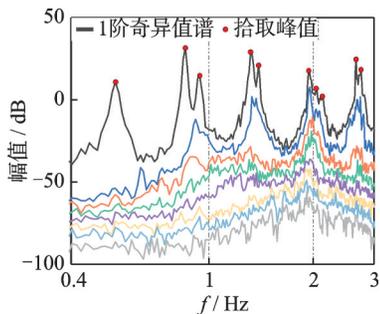


图 10 FDD 的识别结果

Fig.10 Identification results by FDD

采用所提出算法识别模态参数。最小、最大系统阶次分别取值为 2 和 50;基频保守估计为 0.1 Hz, b 取值为 250。结合异阶系统非等权重稳定点定义

的 COV-SSI 算法计算得到的稳定点提取结果如图 11 所示。为便于对比各阶段效果,按 FDD 的频率结果对稳定点进行初步模态划分,如图 11 中的虚线圈所示。

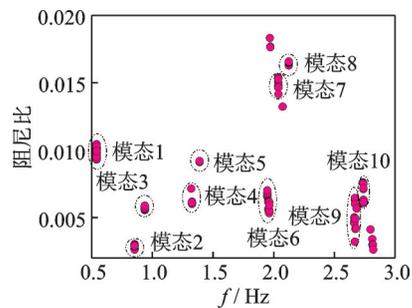


图 11 稳定点提取结果

Fig.11 Results of stable poles extracted

利用结合遍历性搜寻参数的 OPTICS 改进算法对提取结果进行清洗,图 12 为 OPTICS 输出结果。与图 11 对比可知,模态 7 附近的虚假极点以及模态 10 附近虚假极点簇已被自动剔除,且诸多模态内的离群点也被有效去除,使得簇更加致密。

采用结合度矩阵去噪的 SC-DA 算法进行聚类分析。需要说明的是,该桥为大跨柔性结构,存在众

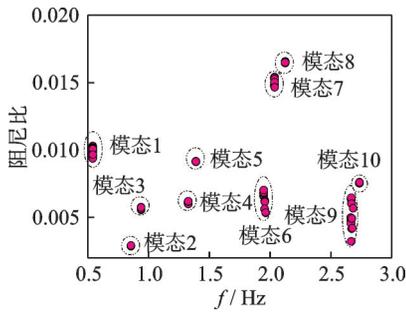


图12 OPTICS输出结果

Fig.12 Results output by OPTICS

多密集模态(模态4~10分别以2个、3个和2个为一组构成密集模态),而密集模态对聚类算法的性能是个严峻考验,其对应的簇常常太接近而容易被聚类为同一模态。SC-DA输出结果如图13所示。可见,各簇被准确划分。

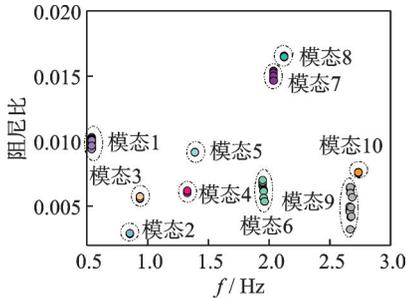


图13 SC-DA输出结果

Fig.13 Results output by SC-DA

通过中值提取各簇的聚类中心,并计算各簇的变异系数。表2为模态参数识别结果。频率和阻尼比的最大变异系数分别为 3.42×10^{-3} 和 9.81×10^{-2} ,离散程度较小,说明簇比较致密,去噪效果较好。分别将FDD与本研究方法识别的频率做差,最大值仅为0.012 3 Hz,说明本研究方法在实现自动化的同

表2 模态参数识别结果

Tab.2 Identification results of modal parameters

阶次	频率		阻尼比	
	数值/Hz	变异系数	数值/%	变异系数
1	0.539	2.20×10^{-4}	0.953	3.55×10^{-2}
2	0.853	8.34×10^{-6}	0.291	4.43×10^{-3}
3	0.936	6.92×10^{-5}	0.563	1.25×10^{-2}
4	1.325	2.44×10^{-5}	0.602	9.67×10^{-3}
5	1.387	9.77×10^{-6}	0.916	1.86×10^{-3}
6	1.945	3.42×10^{-3}	0.660	8.78×10^{-2}
7	2.035	1.01×10^{-4}	1.533	1.63×10^{-2}
8	2.122	1.07×10^{-4}	1.653	1.87×10^{-3}
9	2.663	7.47×10^{-4}	0.471	9.81×10^{-2}
10	2.733	8.89×10^{-5}	0.758	2.98×10^{-3}

时具有较高的精度。

前10阶振型识别结果如图14所示。桥塔位于225 m处的位置,由于该桥为非对称异型结构,且传感器布置不密集,故振型特征并不显著,但可以看出,前5阶是以225 m跨为主的主梁振型,后5阶为整体主梁的振型。

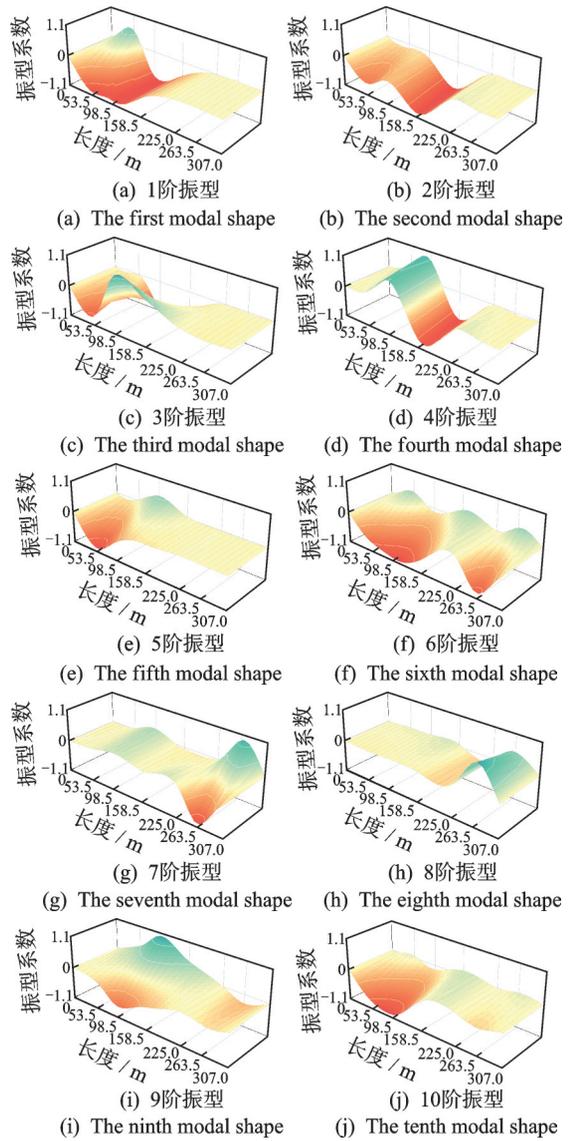


图14 前10阶振型识别结果

Fig.14 The first ten modal shape identified

3.3 MPC和MPD在软硬标准中的局限性

软硬标准^[7]是目前较为流行的虚假极点自动去除方法,而MPC和MPD是其重要指标。笔者以图13中各簇的MPC,MPD中值为代表值,研究其在软硬标准中的适用性,各簇的MPC中值和MPD中值分别如图15,16所示。MPD(理想值为0)中仅第7,8阶模态的值小于0.5, MPC(理想值为1)中尽管各值均大于0.5,但平均水平较低,若将二者作为

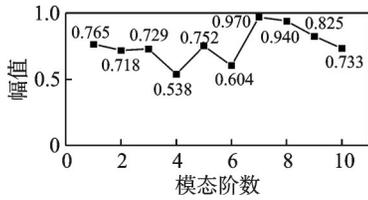


图 15 各簇的 MPC 中值

Fig.15 MPC median of each cluster

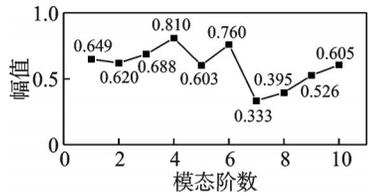


图 16 各簇的 MPD 中值

Fig.16 MPD median of each cluster

硬标准将出现真实模态被去除的情况。此外,不同模态的 MPC,MPD 值差异性较大,若将其作为执行软标准的聚类特征,会使真实模态在多维空间中的簇变得稀疏,从而导致 2-means 算法对于虚假极点的误判。因此,不论是软标准还是硬标准,MPC,MPD 的考虑都需要格外谨慎。

3.4 在线识别

如图 17 所示,为实现在线模态识别,采用滑动窗口的思想。其中: t_w 为窗口截取待分析数据的时长,称为窗口时长; t_a 为分析窗内数据所消耗的时间,称为分析耗时; t_s 为相邻两个窗口的间隔时间,称为间隔时长。根据设置的间隔时长依次递进滑动窗口执行模态自动分析(各窗口中点时刻表征模态结果对应的时刻),同时删除间隔时长对应的历史数据以释放存储空间,即可实现在线分析。

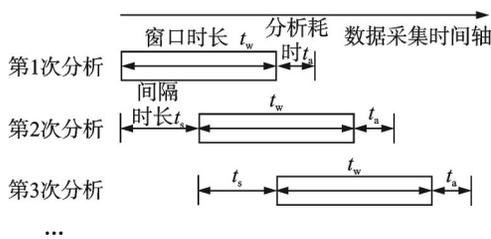


图 17 滑动窗口示意图

Fig.17 Diagram of sliding window

实时监测时需满足条件 $t_s > t_a$, 否则会造成数据量持续累积,导致内存负荷过载^[6],且所分析的时刻将不断滞后于真实时刻,失去实时性。当满足该条件时,即使因计算机、网络等问题造成某一次 t_a 大于 t_s ,此后数据积累量与分析时刻的滞后水平也会逐渐回归正常状态,这是由 t_s 与 t_a 的差值决定的。

笔者采用 2020 年 6 月 4 日 10 时至 13 时的加速

度响应记录, t_w 取 10 min, t_s 取 5 min($> t_a$)。分别采用文献[5]中结合层次聚类算法的 COV-SSI 方法和本研究方法来识别结构的模态参数。本研究方法识别结果如图 18 所示。文献[5]方法识别结果如图 19 所示。其中,红色虚轴表示此次识别发生模态遗漏。对比可知:文献[5]方法遗漏模态次数较多,主要集中在模态 6,7,8 处,说明该聚类算法难以处理密集模态的情况;本研究方法发生遗漏次数较少,整体效果准确且稳定。

一般而言,若某次识别的模态阶数为真实值,则各模态参数也均为真实值,否则表示发生模态遗漏或包含重复模态或虚假模态。因此,将在线识别的模态阶数进行统计,以此衡量识别的准确率。模态阶数的识别次数如图 20 所示。可见:文献[5]方法准确识别的次数较少,且整体表现出较高的离散性;本研究方法的准确次数较多,且准确率达到 82.86%,显著高于文献[5]方法。

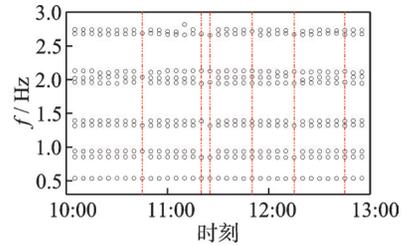


图 18 本研究方法识别结果

Fig.18 Identification results by the proposed method

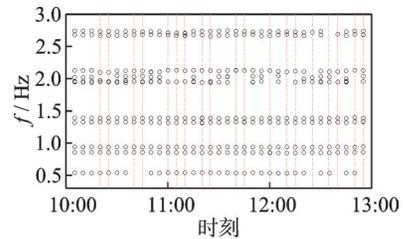


图 19 文献[5]方法识别结果

Fig.19 Identification results by Ref.[5] method

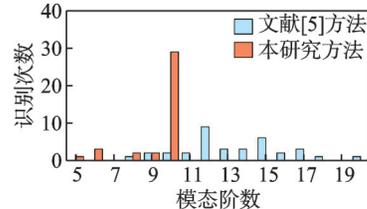


图 20 模态阶数的识别次数

Fig.20 Number of times of modal order identified

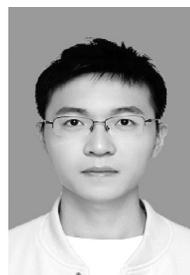
4 结束语

因默认各阶系统等权重关系,传统稳定点定义方式不利于聚类分析。提出的结合遍历性搜索参数

的OPTICS改进算法可有效去除虚假极点。提出的结合度矩阵去噪的SC-DA算法可自动判断模态阶数,并准确聚类各阶模态。软硬标准中MPC,MPD项需谨慎考虑。含有密集模态的外滩大桥的识别结果表明,所提出方法可以在无人工干预的情况下自动、准确地识别模态参数,且在线识别的准确率高于结合层次聚类算法的COV-SSI方法,具有一定的工程应用前景。

参 考 文 献

- [1] FAVARELLI E, GIORGETTI A. Machine learning for automatic processing of modal analysis in damage detection of bridges[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-13.
- [2] CHEYNET E, JAKOBSEN J B, SNÆBJÖRNSSON J. Damping estimation of large wind-sensitive structures [J]. Procedia Engineering, 2017, 199: 2047-2053.
- [3] 常军, 张启伟, 孙利民. 随机子空间产生虚假模态及模态遗漏的原因分析[J]. 工程力学, 2007, 24(11): 57-62.
CHANG Jun, ZHANG Qiwei, SUN Limin. Analysis how stochastic subspace identification brings false modes and mode absence [J]. Engineering Mechanics, 2007, 24(11): 57-62. (in Chinese)
- [4] PEETERS B A, ROECK G U. Reference-based stochastic subspace identification for output-only modal analysis[J]. Mechanical Systems and Signal Processing, 1999, 13(6): 855-878.
- [5] MAGALHÃES F, CUNHA Á, CAETANO E. On-line automatic identification of the modal parameters of a long span arch bridge [J]. Mechanical Systems and Signal Processing, 2009, 23(2): 316-329.
- [6] 梁鹏, 贺敏, 张阳, 等. 实时在线桥梁模态参数自动识别[J]. 振动、测试与诊断, 2021, 41(1): 76-84.
LIANG Peng, HE Min, ZHANG Yang, et al. Real-time online automatic bridge modal identification [J]. Journal of Vibration, Measurement & Diagnosis, 2021, 41(1): 76-84. (in Chinese)
- [7] REYNDERS E, HOUBRECHTS J, DE R G. Automated interpretation of stabilization diagrams[M]. New York: Springer, 2011: 189-201.
- [8] 毛国军, 段立娟. 数据挖掘原理与算法[M]. 北京: 清华大学出版社, 2016: 169-196.
- [9] PEETERS B. System identification and damage detection in civil engineering[D]. Leuven: Katholieke Universiteit Leuven, 2000.
- [10] 王燕, 杭晓晨, 姜东, 等. 协方差驱动随机子空间的Toeplitz矩阵行数选择方法[J]. 振动与冲击, 2015, 34(7): 71-75.
WANG Yan, HANG Xiaochen, JIANG Dong, et al. Selection method of Toeplitz matrix row number based on covariance driven stochastic subspace identification [J]. Journal of Vibration and Shock, 2015, 34 (7) : 71-75. (in Chinese)
- [11] REYNDERS E, ROECK G D. Reference-based combined deterministic-stochastic subspace identification for experimental and operational modal analysis [J]. Mechanical Systems and Signal Processing, 2008, 22(3): 617-637.
- [12] OVERSCHEE P V, MOOR D B. Subspace identification for linear systems: Theory-implementation-applications [M]. Dordrecht, the Netherlands: Kluwer Academic Publishers, 1996: 88-92.
- [13] MOHANTY P, REYNOLDS P, PAVIC A. Automated interpretation of stability plots for analysis of a non-stationary structure [C] // 25th Conference and Exposition on Structural Dynamics. Orlando, USA, 2007: 2198-2204.
- [14] 李爱群, 张超, 邓扬, 等. 基于随机子空间法的结构模态参数自动识别方法[J]. 东南大学学报(自然科学版), 2023, 53(1): 53-60.
LI Aiqun, ZHANG Chao, DENG Yang, et al. Automatic identification method for structural modal parameters based on stochastic subspace identification [J]. Journal of Southeast University (Natural Science Edition), 2023, 53(1): 53-60. (in Chinese)
- [15] ZHANG X C, LI J W, YU H. Local density adaptive similarity measurement for spectral clustering [J]. Pattern Recognition Letters, 2011, 32(2): 352-358.
- [16] LUXBURG U. A tutorial on spectral clustering [J]. Statistics and Computing, 2007, 17(4): 395-416.
- [17] BACH F, JORDAN M. Learning spectral clustering [C] // Proceedings of the 16th International Conference on Neural Information Processing Systems. Cambridge, United States: Massachusetts Institute of Technology Press, 2003: 305-312.
- [18] FISCHER I, POLAND J. Amplifying the block matrix structure for spectral clustering [C] // 14th Annual Machine Learning Conference of Belgium and The Netherlands. Bruges, Belgium: Centre for Telematics and Information Technology, 2005: 21-28.



第一作者简介:张超,男,1996年8月生,硕士生。主要研究方向为模态识别。
E-mail: jintiandehaifeng@163.com

通信作者简介:邓扬,男,1984年7月生,博士、教授、博士生导师。主要研究方向为结构健康监测。
E-mail: dengyang@bucea.edu.cn