

基于改进遗传算法的动载荷识别研究*

秦远田^{1,2}, 唐甜¹, 张炉平¹

(1. 南京航空航天大学航天学院 南京, 210016)

(2. 深空星表探测机构技术工信部重点实验室 南京, 210016)

摘要 针对同时识别动载荷位置和大小中的矩阵病态问题, 以及将反问题转化为正向识别的最值问题, 采用自适应算法和非线性规划对遗传算法(genetic algorithm, 简称 GA)进行改进, 将改进后的混合算法用于求解最值问题, 得到动载荷参数。首先, 建立频域识别模型, 把理论值与测量值的差值的二范数最小化作为优化目标函数; 其次, 将该目标函数作为混合算法的评价函数来识别动载荷参数; 最后, 进行简支梁动载荷识别的仿真和实验, 对比了正向识别和逆系统法, 讨论了非线性规划代数与噪音对混合算法的影响。研究结果表明: 正向识别避免了矩阵求逆病态问题; 相比遗传算法和自适应遗传算法, 所提出算法可同时更准确和稳定地识别多个动载荷参数, 且抗噪性更强。

关键词 动载荷识别; 遗传算法; 自适应算法; 非线性规划

中图分类号 TH825; O327

引言

现代工程结构中动载荷形式复杂多样, 其识别方法差异较大, 涉及到冲击工程学^[1]等领域和学科。由于动载荷识别反问题的不适定性和噪声敏感性等问题, 使动载荷识别不准确和存在非唯一解^[2]。动载荷识别方法主要分为频域法^[3]和时域法。随着正则化技术^[4]出现, 神经网络算法^[5]、卡尔曼滤波法^[6]和遗传算法^[7]等智能优化算法逐渐被开发, 研究人员将其用于动载荷识别研究。

求解动载荷时, 令逆问题转化为求解目标函数的最值问题, 选择相应的优化算法进行求解, 其中目标函数的一般形式是测量值与理论值之间的范数^[8]。严刚等^[9]把实际测量值与模型计算值的差值最小化作为优化目标函数, 使用自适应搜索遗传算法, 将作用在加强筋复合材料上冲击载荷的位置和大小的识别问题转化为优化问题。裘著有等^[10]对于结构动载荷逆问题中的不适定问题, 采用微种群遗传算法获取最佳参数, 避免矩阵求逆病态等问题。Wang 等^[11]基于最大相对误差最小化的原则, 将多目标优化反问题转为单目标优化正问题, 并采用遗传算法搜索该最优解, 避免了多目标优化反问题的病态性和奇异性。孙文娟^[12]利用改进的自适应遗传算法, 提出了一种爆炸冲击响应谱的时域合成的方

法。Wu 等^[13]将待识别的动载荷参数用特定基函数叠加表示, 为求解参数和构造动载荷采用遗传算法, 明显减少了不适定性。张景等^[14]为提高载荷定位效率, 提出了新的动载荷位置和时间历程识别方法。张志宏等^[15]通过构建遗传算法优化误差反向传播(back propagation, 简称 BP)神经网络载荷识别模型, 揭示了履带行驶系统运动过程中的振动与应力载荷之间的关系。目前, 对于同时识别动载荷的位置和大小的研究还相对较少。

笔者在已有的分离激励位置和幅值变量的基础上, 提出使用基于遗传算法改进的混合算法来正向识别参数的方法, 避免矩阵求逆病态问题, 提高了识别准确度。由于 L_2 范数是高斯白噪音的最佳最小二乘近似^[16], 因此把模型计算值与实际测量值差值的二范数最小化作为目标函数, 应用混合算法对目标函数进行求解。用数值仿真和实验来验证混合算法的实用性, 讨论非线性规划代数与噪音对动载荷识别效率和准确度的影响。

1 结构动载荷识别力学模型建立

1.1 单点单频激励识别

在频域中, 外部单频激励 F 的频率为 ω , 幅值为 a 。单输入单输出系统的激励幅值和加速度响应幅

* 国家自然科学基金资助项目(12172168)

收稿日期: 2022-04-19; 修回日期: 2022-06-21

值的关系式为

$$\bar{a} = h(x, s, \omega) a \quad (1)$$

其中: \bar{a} 为加速度响应信号的幅值; h 为加速度频响函数,包含了系统的激励作用位置 s 和响应作用位置 x 。在动载荷未知的系统中, s 和 a 为未知量。

由于 s 和 a 是耦合在一起的,因此为了同时识别 s 和 a ,将变量 s 从 $h(x, s, \omega)$ 分解出来。根据模态叠加理论对式(1)进行分解,在点 s 施加激励 F ,响应点 x 的加速度频响函数为

$$|H(x, s, \omega)| = \sum_{n=1}^{\infty} \frac{\omega^2 \varphi_n(x) \varphi_n(s)}{M_n \sqrt{(\bar{\omega}_n^2 - \omega^2)^2 + (2\zeta_n \bar{\omega}_n \omega)^2}} \quad (2)$$

其中: n 为模态阶数; $\varphi_n(x)$ 为响应点 x 的第 n 阶的模态振型值; $\varphi_n(s)$ 为激励位置 s 的第 n 阶的模态振型值; M_n 为第 n 阶的模态质量; $\bar{\omega}_n$ 为第 n 阶固有圆频率; ζ_n 为第 n 阶阻尼比。

将式(2)代入式(1),并将 s 从 $h(x, s, \omega)$ 分离出来,得到单点多频激励频域动载荷参数化识别模型为

$$\bar{a} = \mathbf{A} \mathbf{P} \quad (3)$$

其中: $\mathbf{A} = [\Lambda_1, \Lambda_2, \dots, \Lambda_n]$; $\mathbf{P} = [P_1, P_2, \dots, P_n]^T$;

$$P_n = a \varphi_n(s); \Lambda_n = \frac{\omega^2 \varphi_n(x)}{M_n \sqrt{(\bar{\omega}_n^2 - \omega^2)^2 + (2\zeta_n \bar{\omega}_n \omega)^2}}。$$

。

1.2 单点多频激励识别

多频载荷 F 有 j 个频率,第 j 个频率为 ω_j ,对应幅值为 A_j 。单点多频激励与加速度响应的关系式为

$$\bar{A} = H(x, s, \omega) \mathbf{A} \quad (4)$$

其中: \bar{A} 为加速度响应幅值向量; $H(x, s, \omega)$ 为加速度频响函数矩阵; \mathbf{A} 为多频激励的幅值向量。

建立单点多频激励参数识别模型为

$$\begin{bmatrix} \bar{A}_1 & \bar{A}_2 & \dots & \bar{A}_m \end{bmatrix}^T = \begin{bmatrix} H(x_1, s, \omega_1) & H(x_1, s, \omega_2) & \dots & H(x_1, s, \omega_j) \\ H(x_2, s, \omega_1) & H(x_2, s, \omega_2) & \dots & H(x_2, s, \omega_j) \\ \vdots & \vdots & & \vdots \\ H(x_m, s, \omega_1) & H(x_m, s, \omega_2) & \dots & H(x_m, s, \omega_j) \end{bmatrix} \begin{bmatrix} A_1 \\ A_2 \\ \vdots \\ A_j \end{bmatrix} \quad (5)$$

其中: m 为响应点的个数; \bar{A}_m 为第 m 个响应点的加速度响应幅值; x_m 为第 m 个响应点的位置。

根据模态叠加理论对式(5)进行分解,在点 s 施加激励 F ,响应点 x_m 对应激励频率 ω_j 的加速度频响函数为

$$|H(x_m, s, \omega_j)| = \sum_{n=1}^{\infty} \frac{\omega_j^2 \varphi_n(x_m) \varphi_n(s)}{M_n \sqrt{(\bar{\omega}_n^2 - \omega_j^2)^2 + (2\zeta_n \bar{\omega}_n \omega_j)^2}} \quad (6)$$

其中: $\varphi_n(x_m)$ 为响应点 x_m 的第 n 阶的模态振型值。

将式(6)代入式(5),将 s 从 $H(x, s, \omega)$ 分离出来,得到单点多频激励频域动载荷参数化识别模型为

$$\bar{A} = \sum_{j=1}^{\infty} \mathbf{A} \mathbf{P} \quad (7)$$

$$\text{其中: } \mathbf{A} = \begin{bmatrix} \Lambda_{11} & \Lambda_{12} & \dots & \Lambda_{1n} \\ \Lambda_{21} & \Lambda_{22} & \dots & \Lambda_{2n} \\ \vdots & \vdots & & \vdots \\ \Lambda_{m1} & \Lambda_{m2} & \dots & \Lambda_{mn} \end{bmatrix};$$

$$\Lambda_{mn} = \frac{\omega_j^2 \varphi_n(x_m)}{M_n \sqrt{(\bar{\omega}_n^2 - \omega_j^2)^2 + (2\zeta_n \bar{\omega}_n \omega_j)^2}};$$

$$\mathbf{P} = [P_1, P_2, \dots, P_n]^T; P_n = A_j \varphi_n(s)。$$

1.3 多点多频激励识别

在频域内存在 i 个激励点,第 i 点作用位置为 s_i ,对应的多频激励为 F_i 。该多频激励 F_i 存在 j 个频率,对应第 j 个频率为 ω_{ij} ,其幅值为 A_{ij} 。

对于多点多频激励,其参数化识别模型为式(7)的线性叠加,即

$$\bar{A} = \sum_{i=1}^{\infty} \sum_{j=1}^{\infty} \mathbf{\Pi} \mathbf{Q} \quad (8)$$

$$\text{其中: } \mathbf{\Pi} = \begin{bmatrix} \Pi_{11} & \Pi_{12} & \dots & \Pi_{1n} \\ \Pi_{21} & \Pi_{22} & \dots & \Pi_{2n} \\ \vdots & \vdots & & \vdots \\ \Pi_{m1} & \Pi_{m2} & \dots & \Pi_{mn} \end{bmatrix};$$

$$\Pi_{mn} = \frac{\omega_{ij}^2 \varphi_n(x_m)}{M_n \sqrt{(\bar{\omega}_n^2 - \omega_{ij}^2)^2 + (2\zeta_n \bar{\omega}_n \omega_{ij})^2}};$$

$$\mathbf{Q} = [Q_1, Q_2, \dots, Q_n]^T; Q_n = A_{ij} \varphi_n(s_i)。$$

考虑实际工程测量时有噪音存在,因此式(8)应写为

$$\bar{A}_{\text{err}} = \bar{A} + \sigma_{\text{err}} \quad (9)$$

其中: \bar{A}_{err} 为实际加速度响应幅值向量; σ_{err} 为噪音向量。

结合最优化理论和最小二乘准则,将式(9)转化为非线性优化问题,即

$$\min Y(s, \mathbf{A}) = \|\bar{A}_{\text{err}} - \bar{A}\|_2 \quad (10)$$

式(10)是一个求解最小值的优化问题。当目标函数 Y 满足优化所需的精度条件时,对应的激励作用位置 s 和激励幅值 A 即为所求值。针对单点单频激励,响应点的数量应不小于待识别的参数数量,而对于多频激励来说,由于一点响应信息包含多个频率和对应频率的幅值信息,因此即使响应点的数量略少于待识别参数数量,仍可识别出多频激励的参数。

2 遗传算法改进

2.1 遗传算法简介

遗传算法是一种基于生物进化机制,通过多次迭代全局搜索适应度值最大的个体,得到最优解的启发式智能算法。GA 在解决非线性和多目标问题上,有较强的全局寻优能力。GA 中的遗传操作(交叉和变异)起着核心作用。交叉操作使个体基因重组,产生适应度值更大的优良个体;变异操作使个体基因突变,打破仅靠交叉操作无法跳出种群进化、陷入局部最优解的局面。

2.2 混合算法

传统 GA 使用的是固定交叉算子和固定变异算子,按照一定的概率判断是否可以交叉或变异。虽然在种群进化初期可快速筛选出适应度差的个体,但可能会在进化后期破坏种群中的优良个体,使算法收敛速度变慢。另外,GA 的局部寻优能力弱,会影响最终寻优结果的准确性。因此,引入自适应算法和非线性规划算法对 GA 进行改进,得到混合算法(hybrid approach,简称 HA)。

自适应算法是将固定遗传算子换成自适应交叉和自适应变异,在遗传进化过程中适应地调整交叉概率和变异概率^[17-18]。自适应交叉概率 P_c 为

$$P_c = \begin{cases} P_{c1} - \frac{(P_{c1} - P_{c2})(f' - f_{\text{avg}})}{f_{\text{max}} - f_{\text{avg}}} & (f' \geq f_{\text{avg}}) \\ P_{c1} & (f' < f_{\text{avg}}) \end{cases} \quad (11)$$

其中: P_{c1} 和 P_{c2} 均为常数,本研究分别设为0.9和0.6; f' 为2个交叉个体中更大的适应度值; f_{avg} 为每代群体的平均适应度值; f_{max} 为每代群体中的最大适应度值。

自适应变异概率 P_m 为

$$P_m = \begin{cases} P_{m1} - \frac{(P_{m1} - P_{m2})(f_{\text{max}} - f)}{f_{\text{max}} - f_{\text{avg}}} & (f \geq f_{\text{avg}}) \\ P_{m1} & (f < f_{\text{avg}}) \end{cases} \quad (12)$$

其中: P_{m1} 和 P_{m2} 均为常数,本研究分别设为0.1和0.01; f 为待变异个体的适应度值。

由式(11)和式(12)可知:在进化前期,种群中的个体适应度较为分散,交叉和变异概率较高,更易产生优良个体;在进化后期,种群适应度值趋于一致或趋于局部最优解,交叉和变异概率相应降低,避免破坏优良个体。为加快收敛速度,使用精英保留法则,让当代适应度值最高的最优个体代替适应度值最差的个体,保障优良个体信息不被丢失。

非线性规划是一种求解目标函数或约束条件中有一个或多个非线性函数最优化问题的方法。经典非线性规划算法大多采用梯度下降方法求解,其局部搜索能力较强。利用非线性规划中的内点法,从给定的初始值开始运行,搜索约束条件下非线性多元函数的最小值,并在满足所有设置条件时停止^[19]。由于该算法对设置的初始值敏感,可能会陷入局部极小值,因此与遗传算法相结合,随机生成种群个体,使搜索过程从问题解的一个集合出发,而非单个个体,明显降低陷入局部极小值的概率。

混合算法识别流程步骤如下:

- 1) 建立结构动载荷正向识别模型,在某一位置施加动载荷,布点测量加速度响应;
- 2) 使用实数编码得到动载荷参数对应的染色体,随机生成50个个体作为初始种群,此时遗传代数 $T=0$;
- 3) 将染色体解码为动载荷参数,代入动载荷正向识别模型中,计算加速度响应;
- 4) 把式(10)作为评价函数计算得到目标值,由于是求解最小值问题,故将目标值的倒数视为适应度值,适应度值越大的个体越优良,保留适应度值最大的个体至下一代种群;
- 5) 随机均匀选择个体作为下一代的父个体,根据自适应交叉和自适应变异生成新种群;
- 6) 当遗传代数 T 为非线性规划代数 N (N 为自然数)的整数倍时,使用非线性规划函数对新种群个体寻优;
- 7) 反复执行步骤3~6,直到满足目标值 $\leq 1 \times 10^{-6}$ 、连续两代目标值差值 $\leq 1 \times 10^{-8}$ 或遗传代数 T 达到最大遗传代数,输出最大适应度值的个体。

图1为混合算法流程图。

由于遗传算法具有较强的全局寻优能力,可以跳过函数的局部极小值点,而非线性规划算法局部搜索能力较强,可较为精确地对比函数值大小,最终确定函数的全局极小值。

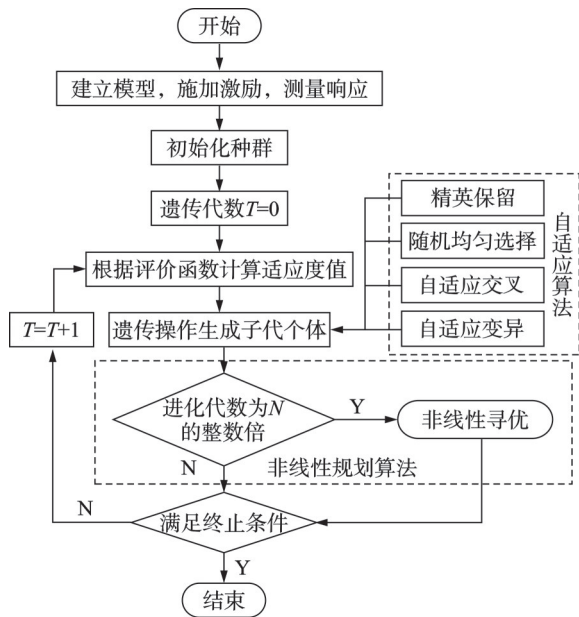


图 1 混合算法流程图

Fig.1 Flow chart of hybrid algorithm

为更好验证混合算法的实用性,基于遗传算法,去除非线性规划算法只保留自适应算法,得到自适应遗传算法(adaptive genetic algorithm,简称AGA)。通过数值仿真和实验,验证正向识别具有稳定性,讨论非线性规划代数 N 对 HA 计算时间与结果的影响,以及 GA,AGA 和 HA 3 种算法的抗噪性。

3 数值仿真算例

以两端简支梁模型为例,通过数值仿真,研究混合算法对于正向识别动载荷参数的有效性。其中:简支梁模型轴向长度为 0.7 m;截面尺寸为 $0.04 \text{ m} \times 0.008 \text{ m}$;材料属性中弹性模量为 210 GPa;密度为 7800 kg/m^3 ;泊松比为 0.3。

3.1 单点单频激励识别

在距离简支梁一端 $s = 0.37 \text{ m}$ 处施加一个正弦载荷 $F = 36\sin(11\pi t)$,以距离一端 0.11 m 和 0.63 m 两处作为加速度响应测量点。考虑测量中存在噪音,故在加速度响应中加入 10 dB 的高斯白噪音。将含 10 dB 高斯白噪音的加速度响应时域信号进行傅里叶变换,转换到频域,得到对应的幅频特性。使用正向识别的 GA,AGA 与 HA 3 种算法同时识别幅值 A 和位置 s ,其中,GA、AGA 和 HA 的最大遗传代数设为 100。为了与正向识别作为对比,按照文献[14]中分离变量的思想,使用需要矩阵求逆的逆

系统法和奇异值分解法识别参数。载荷参数误差 ϵ 和平均误差 η 的计算公式分别为

$$\epsilon_a = \frac{\|I_a - T_a\|_2}{\|T_a\|_2} \times 100\% \quad (13)$$

$$\eta = \frac{1}{b} \sum_{a=1}^b \epsilon_a \quad (14)$$

其中: I_a 和 T_a 分别为第 a 个识别载荷参数与真实载荷参数; b 为识别参数的个数。

误差 ϵ 和平均误差 η 越小,表明识别载荷与真实值越接近,识别准确度越高。表 1 为 10 dB 时单点单频识别结果对比。

表 1 单点单频识别结果对比

Tab.1 Comparison of single point and single frequency identification results

	算法	幅值/N	位置/m
矩阵求逆	逆系统法	35.334 6	0.362 7
	奇异值分解法	35.332 8	0.362 8
正向识别	GA	36.287 8	0.366 9
	AGA	36.281 4	0.366 7
	HA(N=10)	36.287 5	0.366 9

表 1 中 HA($N=10$)为非线性规划代数, N 设为 10。矩阵求逆和正向识别的计算时间均在 2 s 以内。由表 1 可知:选用逆系统法和奇异值分解法识别的平均误差分别为 1.91% 和 1.90%,正向识别的平均误差均为 1% 以内,表明正向识别由于避免了矩阵求逆从而识别准确度更高。

3.2 单点多频激励识别

在距离梁一端 $s=0.27 \text{ m}$ 处施加激励 $F=15\sin(6\pi t)+3\sin(20\pi t)+10\sin(16\pi t)+7\sin(25\pi t)+5.5\sin(\pi t)$,以距离梁一端 0.19,0.32,0.44 和 0.58 m 4 点为响应点。使用 GA,AGA 和 HA 同时识别激励作用位置和大小,最大遗传代数设为 300。表 2 为单点多频识别结果对比。单点多频识别误差对比如图 2 所示。

从表 2 和图 2 可得:无噪时,AGA 的计算时间最短,HA 最长,但 HA 识别结果与 AGA 和 GA 相比,误差为 0,识别结果的准确度较高;含 10 dB 噪音时,3 种算法的计算时间与无噪时相比变化不大,AGA 用时最少,说明自适应算法可加快算法收敛速度。由于包含了噪音,3 种算法识别的平均误差均增加,但 HA 识别的参数误差分布更集中,基本在 12% 以内,其平均误差为 7.06%,分别比 GA 和 AHA 减少了 15% 和 9.46%。

表 2 单点多频识别结果对比

Tab.2 Comparison of single point and multiple frequencies identification results

状态	算法	参数值					位置/m	t/s
		A_1/N	A_2/N	A_3/N	A_4/N	A_5/N		
无噪	GA	14.560 9	2.994 7	9.889 6	6.935 3	5.420 3	0.277 5	5.058 2
	AGA	15.145 8	3.151 7	10.387 7	7.180 3	5.735 9	0.254 3	0.176 8
	HA(N=45)	15.000 0	3.000 0	10.000 0	7.000 0	5.500	0.270 0	7.991 9
10 dB	GA	18.450 3	3.572 8	11.480 6	9.213 5	6.550 8	0.203 3	4.595 9
	AGA	10.552 4	3.732 7	11.223 8	7.587 6	6.046 8	0.231 0	0.154 0
	HA(N=45)	14.499 0	3.190 4	10.945 4	7.409 0	5.857 1	0.239 0	9.415 0




图 2 单点多频识别误差对比

Fig.2 Comparison of single point and multiple frequencies identification error

为了解 HA 中非线性规划代数 N 的大小对动载荷识别的影响,分别对无噪和含 10 dB 噪音的加速度响应曲线应用不同代数 N 的 HA 求解。图 3 为不同代数 N 的结果对比。

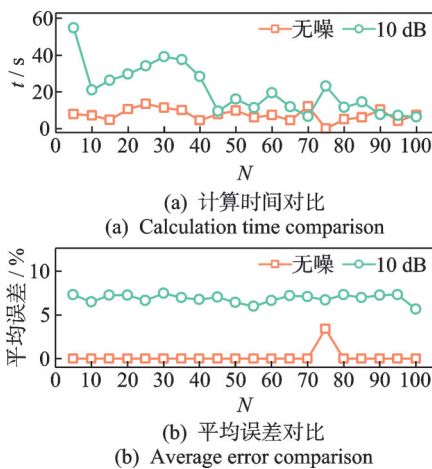


图 3 不同代数 N 的结果对比

Fig.3 Comparison of results for different generations N

从图 3 可得:随着噪音的增加,算法识别时间总体增长,识别误差增大;若代数 N 设置合理,无噪时和含 10 dB 噪音的计算时间相对接近。无噪时,除代数为 75 时,虽然识别时间长短不一,但其他不同代数的 HA 识别的结果均一致,平均误差为 0,说明 HA 算法稳定性较强。当代数 N 为 75 时,计算时间

大幅减少,误差增加至 3.42%,是因为算法未进行非线性规划就提前收敛输出结果,此时得到局部最优解。当含 10 dB 噪音时,代数 N 在 5~40 区间比在 45~100 的计算时间长,是因为代数 N 较小时,在算法的早期搜索阶段,种群中的个体适应度值不高、优良个体不多,使得算法需多次迭代进化增加优良个体,导致时间增长。当 N 较大时,遗传算法在前 $N-1$ 代进化的优良个体增多,更易得到最优解。当含 10 dB 噪音时,算法识别的平均误差在 6%~8% 之间,相差不大。因此,代数 N 不易设置过低,避免计算时间增长;也不易设置过高,避免在前 $N-1$ 代因算法陷入局部最优解而提前结束优化,无法得到精确解。

3.3 多点多频激励识别

在梁上选取多个激励作用点施加激励,表 3 为载荷大小及位置。以距离梁一端 0.12, 0.21, 0.47 和 0.65 m 4 点为响应点。

表 3 载荷大小及位置

Tab.3 Load size and location

激励	频率/rad	幅值/N	位置/m
F_1	17π	24	0.28
F_2	23π	30	0.28
F_3	44π	15	0.51
F_4	56π	6.5	0.51

在测量得到的加速度响应曲线中,加入 10 dB 的高斯白噪音。使用 GA、AGA 和 HA 3 种算法同时识别激励大小和作用位置,最大代数设为 300。表 4 为不同噪音情况下不同算法的载荷识别。图 4 为不同噪音下多点多频识别误差对比。

由表 4 和图 4 可知:无噪时,GA 的幅值平均误差为 5.84%,位置平均误差为 4.43%;AGA 识别时间最短,幅值平均误差为 9.87%,位置平均误差为 7.20%;HA 虽然识别时间较长,但幅值平

均误差为 3.66% 位置平均误差为 1.64%,识别结果准确度最高。在含有 10 dB 高斯白噪音的动载荷识别中,AGA 识别时间依然最短,而 HA 识别时间最长。HA 识别结果误差分布更集中,且平均误差比 AGA 和 GA 更小。总体而言,随着噪音的增加,GA,AGA 和 HA 算法的识别误差均会随之增大,但对识别时间影响较小。HA 识别结果更接近真实动载荷的作用位置和大小,且识别更稳定。

表 4 不同算法的载荷识别
Tab.4 Load identification of different algorithms

状态	算法	参数值								t/s
		A_1/N	s_1/m	A_2/N	s_2/m	A_3/N	s_3/m	A_4/N	s_4/m	
无噪	GA	24.558 3	0.284 8	29.444 2	0.270 6	14.519 2	0.505 0	5.462 4	0.450 4	4.836 5
	AGA	25.612 0	0.276 2	30.691 6	0.271 5	11.557 7	0.404 0	6.988 4	0.528 4	0.180 2
	HA(N=45)	23.898 6	0.280 5	29.991 2	0.280 2	14.135 9	0.495 9	7.046 5	0.528 1	11.160 6
10 dB	GA	27.424 5	0.209 0	29.292 0	0.279 4	12.750 2	0.465 0	7.352 0	0.536 7	4.497 2
	AGA	22.560 0	0.332 8	35.102 8	0.201 0	13.837 6	0.490 0	7.470 0	0.541 2	0.179 0
	HA(N=45)	25.078 9	0.243 0	30.501 1	0.259 0	12.885 1	0.468 2	7.074 5	0.530 0	16.692 3

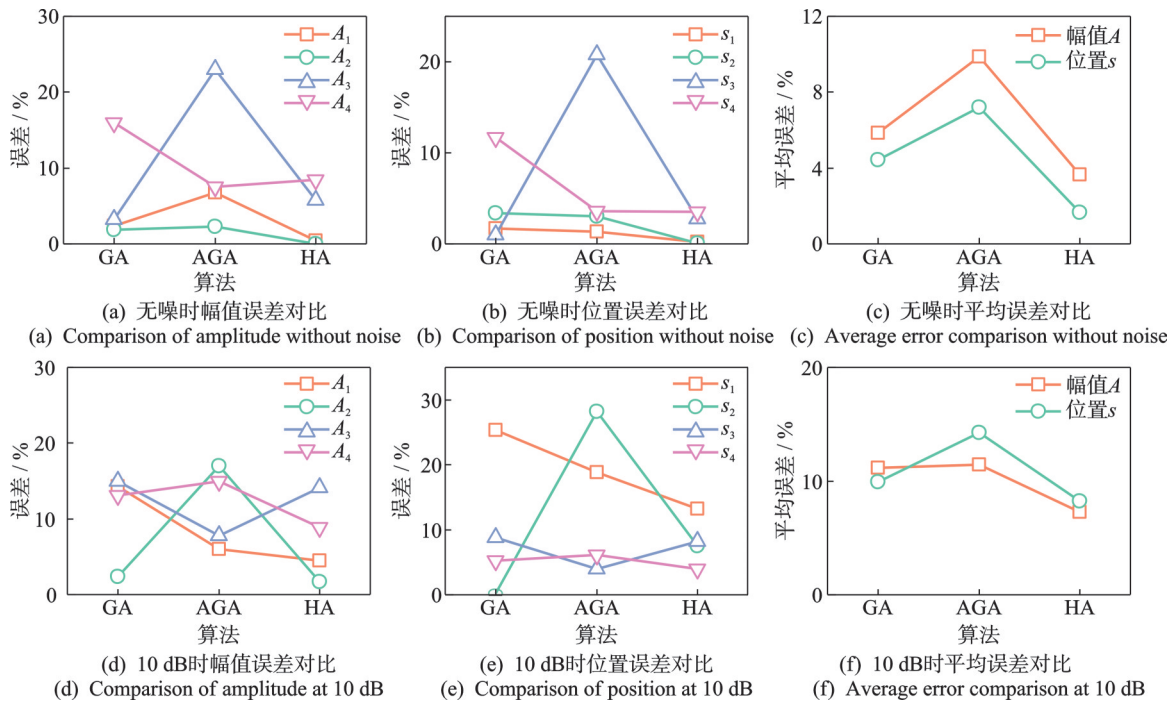


图 4 多点多频识别误差对比

Fig.4 Comparison of multiple points and multiple frequencies identification error

可见:正向识别可以避免由于矩阵求逆带来的病态性;根据所求动载荷参数量适当设置 HA 的非线性规划代数 N ,可提高计算效率和识别准确度;HA 比 GA 和 AGA 的稳定性和准确性更高,抗噪性更强。

4 简支梁实验

为进一步验证 HA 对同时识别动载荷大小和作用参数的准确性和工程实用性,笔者利用简支梁模型进行动载荷识别实验。图 5 为实验物件图。表 5

为简支梁模型参数。



图5 实验物件图

Fig.5 Figure of the test specimen

表5 简支梁模型参数

Tab.5 Model parameters for simply supported beams

长度/m	宽度/m	高度/m	弹性模量/ GPa	密度/ ($\text{kg}\cdot\text{m}^{-3}$)
0.7	0.04	0.008	210	7 800

在梁一端 $s=0.14\text{ m}$ 处施加激励 $F = \sin(40\pi t) + 2\sin(80\pi t)$, 在 0.28 m 和 0.49 m 位置放置加速度传感器, 将获取的加速度响应时域信号进行傅里叶变换, 转换到频域内。使用 GA, AGA 和 HA 算法同时识别激励的幅值和作用位置, 最大代数设为 300。表 6 为不同算法下的载荷识别。载荷识别结果误差对比如图 6 所示。

表6 不同算法下的载荷识别

Tab.6 Load identification of different algorithms

算法	参数值			t/s
	A_1/N	A_2/N	位置/m	
GA	0.935 0	1.875 6	0.150 7	4.393 8
AGA	0.944 5	1.876 4	0.150 5	0.145 9
HA($N=15$)	1.050 0	2.111 3	0.132 1	2.408 9




图6 载荷识别结果误差对比

Fig.6 Load identification results error comparison

由表 6 和图 6 可得: 3 种算法中 AGA 识别时间最短, 表明自适应算法可加快算法收敛速度, 减少计算时间; 与 GA 相比, AGA 平均识别误差降低了 0.38%, 但仍不理想; HA 在 AGA 的基础上引入了非线性规划, 虽然增加了计算时间, 但计算准确度提高, 误差集中分布在 6% 以下, 且平均误差最小。因此, 非线性规划对改进遗传算法的影响效果得到进一步验证。

5 结 论

1) 建立了动载荷频域正向识别模型, 可避免由于矩阵求逆带来的病态性。基于遗传算法, 利用自适应算法和非线性规划对其进行改进, 其中: 自适应算法将固定遗传算子变为自适应遗传算子, 加快了收敛速度; 非线性规划算法改善了算法的局部寻优能力。由此得到的混合算法能提高同时识别动载荷的位置和参数大小的准确度。

2) 进行了单点单频激励、单点多频激励和多点多频激励的仿真及实验, 讨论了非线性规划代数 N 和噪音对混合算法识别动载荷参数的影响。结果表明, 选择合适的非线性规划代数 N 可加快算法收敛速度和提高准确度。混合算法虽然识别时间较长, 但相较于遗传算法和自适应遗传算法, 其识别结果更稳定和准确, 抗噪性更强。

3) 通过基于遗传算法改进的混合算法正向识别简支梁上的简谐载荷的位置与大小, 来验证该方法的可行性, 且周期性载荷可用简谐载荷叠加表示, 说明该理论对周期性载荷同样适用。

参 考 文 献

- [1] SEKULA K, GRACZYKOWSKI C, HOLNICKI-SZULC J. On-line impact load identification[J]. Shock and Vibration, 2013, 20(1): 123-141.
- [2] LIU R X, DOBRIBAN E, HOU Z C, et al. Dynamic load identification for mechanical systems: a review[J]. Archives of Computational Methods in Engineering, 2022, 29: 831-863.
- [3] BARTLETT F D, FLANNELLY W G. Model verification of force determination for measuring vibratory loads[J]. Journal of the American Helicopter Society, 1979, 24(2): 10-18.
- [4] 王能建, 任春平, 刘春生. 一种新型分数阶 Tikhonov 正则化载荷重构技术及应用[J]. 振动与冲击, 2019, 38(6): 121-126, 158.
WANG Nengjian, REN Chunping, LIU Chunsheng. Novel fractional order Tikhonov regularization load reconstruction technique and its application[J]. Journal of Vibration and Shock, 2019, 38(6): 121-126, 158. (in Chinese)
- [5] CHEN G R, LI T G, CHEN Q J, et al. Application of deep learning neural network to identify collision load conditions based on permanent plastic deformation of shell structures[J]. Computational Mechanics, 2019, 64(2): 435-449.

- [6] CUMBO R, TAMAROZZI T, JANSSENS K, et al. Kalman-based load identification and full-field estimation analysis on industrial test case[J]. *Mechanical Systems and Signal Processing*, 2019, 117: 771-785.
- [7] WORDEN K, STASZEWSKI W J. Impact location and quantification on a composite panel using neural networks and a genetic algorithm [J]. *Strain*, 2000, 36(2): 61-68.
- [8] 谢兵, 谢博群, 张猛, 等. 基于粒子群的改进智能算法在载荷识别中的应用[J]. *中南大学学报(自然科学版)*, 2019, 50(2): 343-349.
XIE Bing, XIE Boqun, ZHANG Meng, et al. Application of improved intelligent algorithm based on particle swarm in load identification [J]. *Journal of Central South University (Science and Technology)*, 2019, 50(2): 343-349. (in Chinese)
- [9] 严刚, 周丽. 加筋复合材料结构的冲击载荷识别[J]. *航空学报*, 2008, 29(5): 1150-1156.
YAN Gang, ZHOU Li. Impact load identification for stiffened composite structure [J]. *Acta Aeronautica ET Astronautica Sinica*, 2008, 29(5): 1150-1156. (in Chinese)
- [10] 袭著有, 闫云聚, 常晓通. 基于遗传算法的动态载荷识别优化方法[J]. *机械强度*, 2015, 37(4): 593-597.
XI Zhuyou, YAN Yunju, CHANG Xiaotong. Optimization method of dynamic load identification based on genetic algorithm [J]. *Journal of Mechanical Strength*, 2015, 37(4): 593-597. (in Chinese)
- [11] WANG C, YU F, TAO L, et al. Uncorrelated multi-source random dynamic load identification based on minimization maximum relative errors and genetic algorithm [J]. *International Journal of Applied Electromagnetics and Mechanics*, 2016, 52 (1/2) : 691-699.
- [12] 孙文娟. 自适应遗传算法的改进及其在爆炸冲击响应谱时域合成优化中的应用研究[D]. 合肥: 中国科学技术大学, 2019.
- [13] WU L, WANG F, DING Z J, et al. An efficient method to reduce ill-posedness for dynamic load identification in short duration wind tunnels[J]. *Journal of Physics: Conference Series*, 2020, 1592: 12038.
- [14] 张景, 张方, 姜金辉. 采用分离变量法的载荷位置识别技术研究[J]. *振动工程学报*, 2021, 34(3): 584-591.
ZHANG Jing, ZHANG Fang, JIANG Jinhui. Identification of dynamic load location based on variable separation method [J]. *Journal of Vibration Engineering*, 2021, 34(3): 584-591. (in Chinese)
- [15] 张志宏, 张宏, 陈有, 等. 基于遗传神经网络的履带行驶系统载荷识别方法[J]. *振动与冲击*, 2022, 41(3): 54-61, 89.
ZHANG Zhihong, ZHANG Hong, CHEN You, et al. Load identification method of track driving system based on genetic neural network [J]. *Journal of Vibration and Shock*, 2022, 41(3): 54-61, 89. (in Chinese)
- [16] MAO Y M, GUO X L, ZHAO Y. A state space force identification method based on Markov parameters precise computation and regularization technique [J]. *Journal of Sound and Vibration*, 2010, 329(15): 3008-3019.
- [17] 曲志坚, 张先伟, 曹雁锋, 等. 基于自适应机制的遗传算法研究[J]. *计算机应用研究*, 2015, 32(11): 3222-3225, 3229.
QU Zhijian, ZHANG Xianwei, CAO Yanfeng, et al. Research on genetic algorithm based on adaptive mechanism [J]. *Application Research of Computers*, 2015, 32(11): 3222-3225, 3229. (in Chinese)
- [18] 袁梦飞, 阚秀, 曹乐, 等. 自适应精英遗传算法的快速车路径规划[J]. *导航定位学报*, 2021, 9(6): 104-111.
YUAN Mengfei, KAN Xiu, CAO Le, et al. Path planning of express vehicle based on adaptive elite genetic algorithm [J]. *Journal of Navigation and Positioning*, 2021, 9(6): 104-111. (in Chinese)
- [19] 史峰, 王辉, 郁磊, 等. *Matlab智能算法30个案例分析* [M]. 北京: 北京航空航天大学出版社, 2011: 17-26.



第一作者简介:秦远田,男,1971年12月生,博士、副研究员。主要研究方向为航天器结构、航天器结构动力学以及动载荷识别。曾发表《Method for dynamic load location identification based on FRF decomposition》(《Aerospace》2023, Vol.10, No.10)等论文。

E-mail: qinyt@nuaa.edu.cn

通信作者简介:唐甜,女,1996年10月生,硕士。主要研究方向为动载荷识别。

E-mail: 1052135638@qq.com