

DOI: 10.7511/jslx20240619001

基于自适应蝗虫算法的结构损伤稀疏正则化评估

刘琪钿, 陈泽鹏*, 杨新华, 陈舟

(佛山大学 土木与交通学院, 佛山 528225)

摘要: 结构状态评估对于保障结构安全服役至关重要, 其中结构损伤识别是核心环节。针对测量不确定性及不完备性容易引发的结构损伤识别不适定性问题, 提出一种基于自适应蝗虫算法与稀疏正则化的结构损伤识别方法, 以获得精确可靠的结构损伤识别结果。首先, 自适应蝗虫算法引入了自适应 Lévy 飞行和精英反向学习策略, 避免结构损伤识别陷入局部最优, 以提高识别结果稳定性; 其次, 融合了稀疏正则化构造模态参数型目标函数, 通过提高结构损伤识别解的稀疏度以实现识别精度和鲁棒性的提高。基准函数测试表明, 自适应蝗虫算法相比标准算法具有更好的全局收敛性和识别稳定性。简支梁的数值与试验结果表明, 所提方法在不完备测量情况下仍可保证可靠的结构损伤识别精度, 并且具有良好的噪声鲁棒性。

关键词: 结构状态评估; 结构损伤识别; 自适应蝗虫算法; 稀疏正则化; 不完备测量

中图分类号: O346.5

文献标志码: A

文章编号: 1007-4708(2025)05-0803-08

1 引言

在结构运维过程中, 结构状态评估是进行结构维修保养、增强结构抗灾能力、提高结构运行效率的重要前提^[1]。其中, 结构损伤识别 SDD (Structural damage detection) 是结构状态评估的核心部分, 涉及两个系统状态间的比较^[2]。我国现已建成的大量超复杂世界级工程^[3] 正面临老龄化和服役条件恶化等挑战^[4], 相关结构损伤识别的研究与应用亟需跟进, 以保证结构安全服役^[5]。

在结构损伤识别方法中, 模型修正是一种常用的方法, 可以实现结构损伤的判定、定位, 甚至定量^[6,7]。该方法通过对初始有限元模型中的损伤相关参数不断迭代修正, 以最小化模型输出响应或特征与实际结构测得值之间的误差, 从而实现与实际结构状态的参数化评估^[8]。相较于其他模型修正法, 群智能算法具有搜索性能高效、迭代初值不敏感、不涉及逆运算等优点, 如粒子群优化算法^[8,9]、蚁群优化算法^[10]、遗传算法^[11]、蝴蝶优化算法^[12]等已在结构损伤识别领域取得成功应用。然而, 在测量不确定性及不完备性的影响下, 群智

能算法容易出现识别精度下降和噪声鲁棒性变差的问题。探索新型改进群智能算法以提高结构损伤识别精度及稳定性成为结构损伤识别领域的一个研究重点。蝗虫优化算法 GOA (Grasshopper optimization algorithm)^[13] 是一种新型群智能算法, 具有结构简单、效果稳定、局部搜索性能较强的优点, 已成功应用于电气工程^[14]、电子商务^[15]、机械工程^[16]等领域。但算法存在个体行为模式固定、易陷入局部最优的问题。

针对测量不确定性及不完备性影响下的结构损伤识别不适定问题, 提出一种自适应蝗虫算法 IGOA-ALOL (Improved grasshopper optimization algorithm by integrating adaptive Lévy flight and elite opposed learning mechanisms) 与稀疏正则化相结合的结构损伤识别方法, 以实现准确的结构状态稀疏正则化评估。自适应蝗虫算法具有 2 个改进, 即自适应 Lévy 飞行和精英反向学习策略。改进策略的引入进一步增强了蝗虫个体行为模式的多样性, 提高优化过程的全局收敛性。同时, 稀疏正则化体现了损伤的稀疏分布特点^[18], 从而提升了在不完备测量和噪声干扰下的结构损伤识别精

收稿日期: 2024-06-19; 修改稿收到日期: 2024-07-27.

基金项目: 国家自然科学基金(52008109; 12072120)资助项目.

作者简介: 陈泽鹏* (1992-), 男, 博士, 副教授 (E-mail: zpchen2014@foxmail.com).

引用本文: 刘琪钿, 陈泽鹏, 杨新华, 等. 基于自适应蝗虫算法的结构损伤稀疏正则化评估[J]. 计算力学学报, 2025, 42(5): 803-810.

LIU Qitian, CHEN Zepeng, YANG Xinhua, et al. An adaptive grasshopper algorithm for sparse-regularization-based structural damage assessment[J]. *Chinese Journal of Computational Mechanics*, 2025, 42(5): 803-810.

度和鲁棒性。CEC(Competition-based evolutionary computation)基准函数测试检验了所提方法的改进效果。此外,简支梁结构的数值仿真及试验损伤工况识别结果表明,所提方法可以准确识别不同工况损伤,且具有良好的噪声鲁棒性。

2 理论方法

2.1 结构损伤识别模型修正法

数学上,结构损伤识别问题可以表达成优化问题为

$$\boldsymbol{\alpha}_{\text{opt}} = \arg_{\boldsymbol{\alpha}} \min J(\boldsymbol{\alpha}) \quad (1)$$

式中 $J(\boldsymbol{\alpha})$ 为目标函数, $\boldsymbol{\alpha}_{\text{opt}}$ 为最优损伤因子向量。损伤因子向量 $\boldsymbol{\alpha}$ 来源于单元刚度折减模型。该模型仅考虑损伤引起的刚度变化,将损伤后的整体刚度矩阵 \mathbf{K}_d 表达为 $\mathbf{K}_d = \sum_{i=1}^{N_{\text{ele}}} (1 - \alpha_i) \mathbf{K}_i$, 其中, \mathbf{K}_i 和 α_i 分别为第 i 个单元的无损单元刚度矩阵和损伤因子, $\alpha_i \in [0, 1)$, N_{ele} 为单元数量。

2.2 结构状态稀疏正则化评估

结构损伤会造成模态特征参数的改变,通过模态特征指标定义目标函数,并最小化目标函数值得到 $\boldsymbol{\alpha}_{\text{opt}}$ 。然而,仅以最小化模型计算与实际测量特征误差为目标,容易出现噪声及不完备测量下的损伤识别结果精度不足问题。考虑到实际结构损伤具有的稀疏分布特征^[19],引入稀疏正则化进行结构状态稀疏正则化评估可以改善问题的不稳定性。在相对频率变化率和模态柔度置信度的基础上,考虑引入 L1 范数作为稀疏正则化项,得到目标函数

$$J(\boldsymbol{\alpha}) = \omega_1 \sum_{i=1}^{N_m} \text{FCR}_i(\boldsymbol{\alpha}) + \omega_2 (1 - \prod_{i=1}^{N_m} \text{MFAC}_i(\boldsymbol{\alpha})) + \lambda \|\boldsymbol{\alpha}\|_1 \quad (2)$$

式中 $\text{FCR}_i(\boldsymbol{\alpha}) = \left| \frac{f_i^{\text{mea}} - f_i(\boldsymbol{\alpha})}{f_i^{\text{mea}} + f_i(\boldsymbol{\alpha})} \right|$ 为第 i 阶相对频率变化率绝对值, f_i^{mea} 和 $f_i(\boldsymbol{\alpha})$ 分别为第 i 阶测量和计算频率, $\text{MFAC}_i(\boldsymbol{\alpha}) = \frac{((\mathbf{F}_i^{\text{mea}})^T \mathbf{F}_i(\boldsymbol{\alpha}))^2}{((\mathbf{F}_i^{\text{mea}})^T \mathbf{F}_i^{\text{mea}})(\mathbf{F}_i^T(\boldsymbol{\alpha}) \mathbf{F}_i(\boldsymbol{\alpha}))}$ 为模态柔度置信度, $\mathbf{F}_i^{\text{mea}}$ 和 $\mathbf{F}_i(\boldsymbol{\alpha})$ 分别为第 i 阶测量和计算模态柔度的对角元素, N_m 为模态阶数。根据文献^[20],权重系数 ω_1 、 ω_2 分别取为 0.1 和 0.9, $\|\boldsymbol{\alpha}\|_1 = |\alpha_1| + |\alpha_2| + \dots + |\alpha_{N_{\text{ele}}}|$, λ 为正则化参数。

2.3 自适应蝗虫算法(IGOA-ALOL)

2.3.1 GOA 原理

GOA 模拟蝗虫在自然界中的种群迁移和觅食行为,将搜索分为探索和开发。在探索阶段,所有

蝗虫个体在当前的解空间中随机跳跃,以遍历整个解区域。蝗虫位置更新同时受到种群中其他个体和最有个体的影响。GOA 的数学模型表示为^[13]

$$X_{i,m}^{l+1} = c^l \cdot$$

$$\sum_{j=1, j \neq i}^{N_{\text{sw}}} \frac{c^l \text{ub}_m - \text{lb}_m}{2} s(d_{ij}^l) \frac{\mathbf{X}_j^l - \mathbf{X}_i^l}{\|\mathbf{X}_j^l - \mathbf{X}_i^l\|_2} + T_m^l \quad (3)$$

式中 $X_{i,m}^{l+1}$ 为第 i 个个体在第 $l+1$ 次迭代的第 m 维位置, N_{sw} 为种群大小, ub_m 和 lb_m 分别为个体第 m 维的上限和下限, $d_{ij} = \|\mathbf{X}_j - \mathbf{X}_i\|_2$ 为第 i 个和第 j 个蝗虫个体之间的欧氏距离,个体间吸引力 $s(d_{ij}) = \frac{1}{2} \cdot \exp\left(-\frac{d_{ij}}{1.5}\right) - \exp(-d_{ij})$ ^[13], T_m^l 表示第 m 维在第 l 次迭代的最优位置,参数 $c^l = c_{\text{max}} - l/L \times (c_{\text{max}} - c_{\text{min}})$ 为线性递减系数, c_{max} 和 c_{min} 分别为该参数的最大值和最小值, l 和 L 分别为当前迭代次数和最大迭代次数。该算法中,蝗虫个体之间的行为模式较为固定,导致算法容易陷入局部最优。因此,引入自适应 Lévy 飞行和精英反向学习策略,以增强群体多样性,从而提高结构损伤识别精度。

2.3.2 自适应 Lévy 飞行

Lévy 飞行通过随机游走产生新解,可以有效地保证全局收敛性。其步长 Lévy(β) $\sim u \cdot v^{-1/\beta}$, 其中 $u \sim N\left(0, \left[\frac{\Gamma(1+\beta) \cdot \sin(0.5\pi\beta)}{\beta \cdot \Gamma(0.5+0.5\beta) \cdot 2^{0.5\beta-0.5}}\right]^{2/\beta}\right)$, $v \sim N(0, 1)$ 。 β 为步长控制参数,其值与大步长出现概率呈反相关关系。利用这种特性,提出自适应 Lévy 飞行策略。该策略引入 β 随迭代自适应变化的情况,即

$$\beta^l = -\left(\cos\left(\frac{l}{L} \cdot \pi\right) + \beta_{\text{max}}\right) \cdot \frac{(\beta_{\text{max}} + \beta_{\text{min}})}{a_1} + a_2 \quad (4)$$

式中上标 l 为第 l 次迭代,系数 a_1 、 a_2 、 β_{min} 和 β_{max} 分别取 14.00、2.25、1.5 和 2.0^[13]。该策略下,迭代早期 β 值较小,可以获得较大步长以提高全局搜索性能;而迭代后期其值增大,步长随之减小,可以快速收敛当前最优解。自适应 Lévy 飞行策略下,蝗虫位置按照下式更新。

$$\mathbf{X}_i^l = \begin{cases} \mathbf{X}_i^{\text{AdpLevy}} & (\text{fit}(\mathbf{X}_i^{\text{AdpLevy}}) < \text{fit}(\mathbf{X}_i^l \& \mathbf{X}_i^{\text{Levy}})) \\ \mathbf{X}_i^{\text{Levy}} & (\text{fit}(\mathbf{X}_i^{\text{Levy}}) < \text{fit}(\mathbf{X}_i^l \& \mathbf{X}_i^{\text{AdpLevy}})) \\ \mathbf{X}_i^l & (\text{其他}) \end{cases} \quad (5)$$

式中 $\mathbf{X}_i^{\text{AdpLevy}} = \mathbf{X}_i^l + \text{Lévy}(\beta^l)$, $\mathbf{X}_i^{\text{Levy}} = \mathbf{X}_i^l + \text{Lévy}(\beta_0)$, 其中 β_0 建议取最优值 1.5^[13]。

2.3.3 精英反向学习

精英反向学习 EOBL(Elite Opposition-Based Learning)可以有效降低算法陷入局部最优的风险,同时弥补反向学习^[17]存在的边界固定、更新方

式简单、搜索经验难以保留等缺点。该策略中,适应度值最好的前 10% 种群通过反向点生成精英反向种群,并替换掉原始种群中适应度较差的后 10% 种群。其他 80% 种群保持不变。其中,精英反向种群的位置确定如下:

$$X_{i,m} = r_{el}(Eu_m + El_m) - X_{i,m} \quad (6)$$

式中 $r_{el} \sim U(0,1)$, Eu_m 和 El_m 分别为精英蝗虫种群在第 m 维的最大和最小值。

2.3.4 IGOA-ALOL 算法流程

融合自适应 Lévy 飞行和精英反向学习的 IGOA-ALOL 算法伪代码列入表 1。

表 1 IGOA-ALOL 伪代码
Tab.1 Pseudo codes of IGOA-ALOL

输入:种群数量 N ,最大迭代次数 L
输出:最优蝗虫个体 α_{opt}
1. 初始化种群
2. 计算每个个体的适应度值
3. α_{opt} = 最佳蝗虫个体
4. While $l < L$
5. 更新参数 c^l 的值
6. for each $bg_i \in BG$
7. 计算并归一化蝗虫之间的距离到区间[1,4]
8. 根据公式更新每一个蝗虫的位置
9. 执行自适应 Lévy 飞行策略
10. end for
11. 对当前迭代的精英个体执行精英反向学习策略
12. 更新全局最优个体 α_{opt}
13. $l = l + 1$
14. end while
15. 返回全局最优位置 α_{opt}

2.4 基于自适应蝗虫算法的 SDD 稀疏正则化方法

结合自适应蝗虫算法与稀疏正则化得到本文结构损伤识别方法流程如图 1 所示。

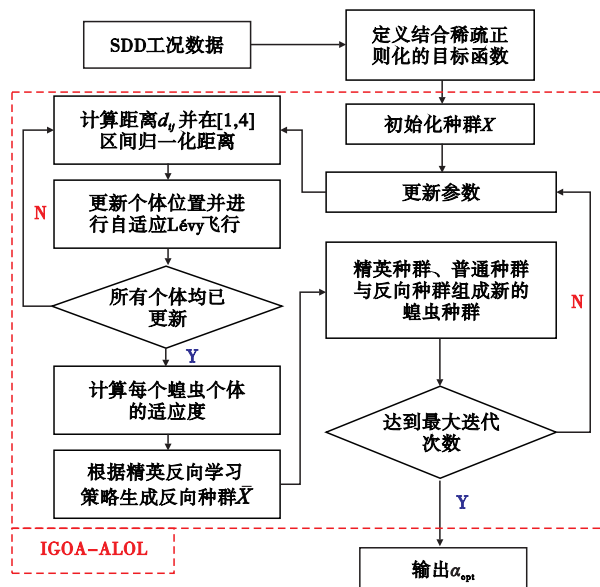


图 1 基于自适应蝗虫算法的 SDD 稀疏正则化方法流程
Fig. 1 Flowchart of SDD based on IGOA-ALOL and sparse regularization

3 数值模拟算例

3.1 CEC 基准函数测试

选择 Sphere、Griewank、Ackley 和 Rastrigin 4 个 CEC 基准测试函数^[18],通过与原始 GOA、蚁狮优化算法 ALO(Ant lion optimizer)、蜻蜓算法 DA(Dragonfly algorithm)、粒子群优化算法 PSO(Particle swarm optimization)和飞蛾扑火算法 MFO(Moth-flame optimization algorithm) 的比较,检验 IGOA-ALOL 求解优化问题的性能。4 个基准函数分别用 F_1 、 F_2 、 F_3 和 F_4 表示,最小适应度值均为 0。

种群数量统一设置为 30,最大迭代次数为 100,优化问题维度为 30。不同算法各执行 10 次独立计算,结果统计如图 2 所示。其中,上下边缘短横线表示适应度最大值和最小值,箱体上下边界表示上下四分位数,中间横线表示中位数。可以看出,对 4 个基准函数的优化结果中,IGOA-ALOL 得到的适应度均最小,其全局优化性能优于另外 5 种算法。其次,IGOA-ALOL 对于 F_1 、 F_2 和 F_3 优化结果的中位数、最值以及上下四分位数几乎重合,其识别稳定性亦优于另外 5 种算法。算法对 F_4 的识别稳定性稍有下降,但次于 GOA。

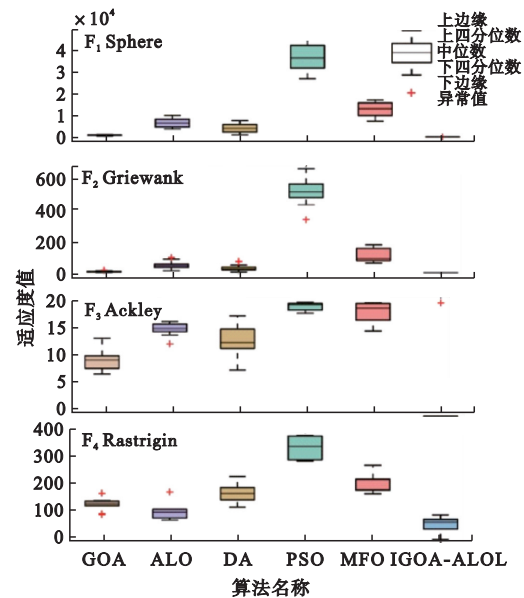


图 2 10 次独立运行结果箱形图
Fig. 2 Boxplot of optimal results for 10 independent runs

3.2 简支梁结构数值算例

以简支梁为例,研究 IGOA-ALOL 的结构损伤识别效果,结构简图及几何尺寸如图 3 所示,梁截面面积 $A = 0.48 \text{ m}^2$,惯性矩 $I = 0.0256 \text{ m}^4$ 。材料弹性模量 $E = 210 \text{ GPa}$,密度 $\rho = 7850 \text{ kg/m}^3$ 。

采用 20 个等长度的两结点四自由度平面弯曲梁单元对结构进行有限元离散。不同算法种群个体数量为 100,最大迭代次数为 100。取 $N_m = 5$ 及竖向自由度方向的振型数据代入式(2)定义的目标函数进行求解。




图 3 简支梁数值仿真模型

Fig. 3 FE model of a 20-element simply-supported beam

群智能算法单次计算存在偶然性,不能代表方法的有效性。因此,对不同损伤工况,本文执行 100 次独立计算,并取均值作为最终识别结果。同时,使用 $DVC100^{[20]}$ 指标定量地评估算法的识别成功率。 $DVC100$ 表示识别损伤因子向量与假设损伤因子向量的夹角余弦等于 1 在多次识别结果中占的百分比,更详细描述可参见文献[20]。

3.2.1 不同改进策略的比较

在不考虑稀疏正则化(即 $\lambda = 0$)的情况下,不同改进策略对表 2 所列损伤工况的结构损伤识别结果如图 4 所示。其中,IGOA-AL 表示在 GOA 仅融入自适应 Lévy 飞行策略,IGOA-OL 表示在 GOA 仅融入精英反向学习策略。

表 2 损伤工况
Tab. 2 Damage cases

工况	类型	损伤程度@损伤单元
1	单损伤	10%@E10
2	两损伤-非对称	10%@E10,10%@E16
3	两损伤-对称	15%@E6,15%@E16
4	三损伤	20%@E6,25%@E11,15%@E16

可以看出,GOA 的识别结果存在较多误判单元且在靠近支座处误判较大,无法有效定位损伤。相比之下,融合改进策略的算法均得到了较为准确的结构损伤识别结果。在单损伤工况中,IGOA-AL、IGOA-OL 和 IGOA-ALOL 均能准确定位损伤,除 IGOA-OL 在 1 号和 9 号单元处存在小幅度误判以外,IGOA-AL 和 IGOA-ALOL 均未见明显损伤误判,而且 IGOA-ALOL 的识别成功率最高,达到 85%。在多损伤工况中,IGOA-AL、IGOA-OL 和 IGOA-ALOL 均出现了不同程度的误判,不过相较而言,IGOA-ALOL 的误判单元最少,且误判单元幅值均最小。




图 4 不同工况的结构损伤识别结果

Fig. 4 SDD results for different damage cases

表 3 给出的 $DVC100$ 值显示,和 GOA 相比,另外三种算法的结构损伤识别成功率均有提升,且 IGOA-ALOL 的提升效果最为明显。这表明,任何一种改进策略均能有效地提高 GOA 的结构损伤识别成功率,而同时融合这两种改进策略的 IGOA-ALOL 具有最好的结构损伤识别性能。

表 3 不同损伤工况的 $DVC100$ 值

Tab. 3 $DVC100$ values of different damage cases

	工况 1	工况 2	工况 3	工况 4
GOA	0%	0%	0%	0%
IGOA-AL	45%	14%	10%	6%
IGOA-OL	39%	22%	16%	2%
IGOA-ALOL	85%	61%	39%	14%

3.2.2 不同群智能算法的比较

进一步比较所提 IGOA-ALOL 与 ALO、PSO 和 MFO 的结构损伤识别结果,对 4 种工况的识别结果如图 5 所示。可以看出,基于 IGOA-ALOL 的结构损伤识别结果中误判单元最少,且误判单元识别值也最小,其最终识别精度较其他群智能算法更高。

3.2.3 稀疏正则化的影响

为了控制各方法变量一致,经步长为 0.01 的网格搜索试验,取稀疏正则化系数 $\lambda = 0.03$,得到基于 IGOA-ALOL、GOA、IGOA-AL、IGOA-OL 的结构损伤识别结果如图 6 所示。




图5 IGOA-ALOL与其他算法的结构损伤识别结果
Fig. 5 SDD results of IGOA-ALOL compared to other swarm intelligence algorithms

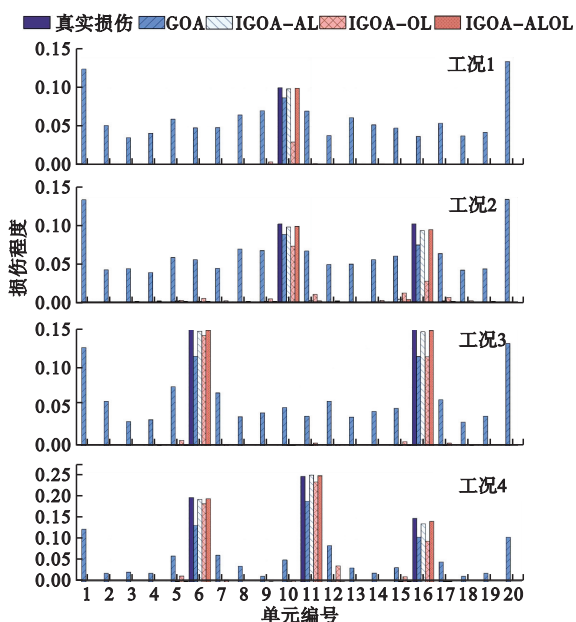


图6 引入L1正则化后的结构损伤识别结果
Fig. 6 SDD results with L1 regularization

可以看出,引入稀疏正则化后,GOA的结构损伤识别精度未见明显提升。而另外三种算法在靠近支座处单元以及损伤位置邻近单元的误判程度均减弱。其中,IGOA-ALOL的识别结果几乎没有误判且真实损伤处的识别值最接近假设损伤。

表4给出的DVC100值显示,引入L1范数正则化后,IGOA-AL、IGOA-OL和IGOA-ALOL的结构识别损伤成功率进一步提升,且以IGOA-ALOL提升效果最为明显。这表明,基于IGOA-ALOL的结构损伤稀疏正则化识别具有最高的识

别精度。

表4 不同损伤工况的DVC100值

Tab. 4 DVC100 values of different damage cases

	工况1	工况2	工况3	工况4
GOA	1%	0%	0%	1%
IGOA-AL	88%	54%	90%	53%
IGOA-OL	11%	0%	45%	10%
IGOA-ALOL	95%	67%	92%	80%

3.2.4 测量不确定性的影响

通过 $r_{noi} = r_{cal}(1 + E_p N_{oise})$ 添加高斯白噪声以模拟实际模态参数的测量不确定性,式中 r_{noi} 、 r_{cal} 分别为有噪声和无噪声数据, E_p 为噪声水平, N_{oise} 为服从 $N(0, 1)$ 的高斯分布随机数。

对工况3和工况4的频率和振型数据同时添加1.5%噪声,得到基于IGOA-ALOL和稀疏正则化的结构损伤识别结果如图7所示。可以看出,在引入稀疏正则化后,IGOA-ALOL在支座处的损伤误判幅度明显下降,而在大部分真实损伤处的识别精度略高于无稀疏正则化的结果,这在一定程度上降低了误判的风险。说明稀疏正则化项的引入对于精度和鲁棒性的提高有一定的帮助。




图7 基于IGOA-ALOL的噪声工况结构损伤识别结果
Fig. 7 SDD results based on IGOA-ALOL under noise

4 实验验证

4.1 实验概述

通过方管截面简支梁模型实验检验本文方法在实际结构损伤识别中的应用效果。简支梁长3 m,横截面尺寸60 mm×140 mm,方管厚度3 mm。材料初始弹性模量210 GPa,密度7800 kg/m³。等间距布置21个ICP333B30加速度传感器,在距离左端支座1.65 m处采用HEV-200激振器激励,以获取加速度响应。结构前三阶频率和模态振型通过LMS SCADAS模态数据采集系统内置算法提取。实验模型、实验设备、激励装置及损伤模拟形式如图8所示。




图8 实验模型、实验设备与损伤设置图
Fig. 8 Diagram of experimental structure, experimental devices and damage settings

4.2 初始无损有限元模型修正

试验过程中,发现实测无损频率与初始有限元模型计算频率之间存在误差,同时结构支座处也非理想固支。因此,选择线密度 ρA 、抗弯刚度 EI 、支座处竖向弹簧刚度 k_v 和扭转弹簧刚度 k_r 四个参数进行初始有限元模型修正,以缩小初始模型与实际结构的误差,从而得到用于后续准确结构损伤识别的基准模型。参数修正后列入表 5。计算及实测频率列入表 6,其中误差值根据(计算值-实测值)/实测值 $\times 100\%$ 计算。修正后,频率计算值与实测值基本吻合,表明修正参数合理有效。

表 5 简支梁模型修正前后参数对比
Tab. 5 Parameters before and after updating

模型修正参数	初始值	修正值	变化率
$\rho A/\text{kg}\cdot\text{m}^{-1}$	9.0792	7.9325	-12.63%
$EI/\text{N}\cdot\text{m}^2$	159950	140560	12.12%
$k_v/\text{N}\cdot\text{m}^{-1}$	∞	5.330e+8	-
$k_r/\text{N}\cdot\text{rad}^{-1}$	0	3.785e+6	-

表 6 实测频率和模型计算频率
Tab. 6 Experimental and calculated frequencies

阶次	实测值/Hz	修正前		修正后	
		计算值/Hz	误差	计算值	误差
1	23.778	23.092	2.89%	23.778	0.00%
2	89.058	92.367	3.72%	89.058	0.00%
3	188.612	207.832	10.19%	188.612	0.00%

4.3 结构损伤模拟与识别

实验室沿高度方向对方管梁进行切割以模拟损伤,4种损伤工况列入表 7。为估算真实损伤,损伤程度依据损伤前后惯性矩的变化进行计算^[21],表 7 结果显示前三阶频率随着单元损伤加剧呈现下降趋势,且第三阶频率下降最为明显。这与理论相吻合,说明实验频率测量值合理有效。

表 7 实验损伤工况及对应测量频率
Tab. 7 Damage cases and corresponding frequencies

工况	裂纹深度@损伤位置	估计损伤程度@损伤单元	测量频率/Hz		
			1阶	2阶	3阶
1	20 mm@0.4	89.1%@3	23.236	82.886	172.675
2	30 mm@0.4	95.2%@3	22.787	78.817	165.016
3	30 mm@0.4 3 mm@2.2	95.2%@3 70.1%@15	22.096	75.093	161.514
4	30 mm@0.4 20 mm@2.2	95.2%@3 89.1%@15	21.067	70.828	158.006

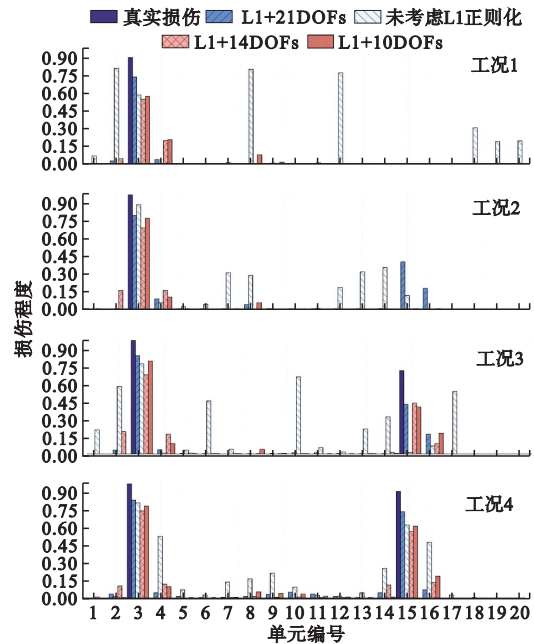


图 9 实验结构的结构损伤识别结果
Fig. 9 SDD results of experimental structure

本节算法参数与上文相同,依据式(2)定义目标函数,得到基于 IGOA-ALOL 的结构损伤识别结果如图 9 所示。其中,L1+xDOFs 表示采用 $\lambda=0.03$ 的正则化系数和仅考虑 x 个竖向自由度振型数据的识别结果,未考虑 L1 正则化表示 $\lambda=0$ 的识别结果。可以看出,在单损伤工况下,不考虑稀疏正则化可以有效地定位损伤,但在真实损伤处的识别精度较低,且 4 号单元存在明显误判。相比之下,结合 IGOA-ALOL 与稀疏正则化不仅识别精度较高,且基本没有误判单元。这说明,本文所提方法在实验工况下亦能够有效实现结构损伤的准确定位和定量。此外,图 9 还对比了仅测量 10 个(2、4、6、8、10、12、14、16、18、20 号结点竖向)和 14 个(1、3、4、6、7、9、10、12、13、15、16、18、19、21 号结点竖向)的结构损伤识别结果,以检验所提方法在不完备振型测量条件下的有效性。可以看出,所提

方法的结构损伤识别精度随着测量自由度有所下降。但当合理选择测点位置时,所提方法在仅获得一半竖向自由度的模态信息的情况下仍然可以较为准确地识别结构的损伤情况。

5 结 论

针对测量不确定性及不完备性引起的结构损伤识别不适定问题,提出了一种融合自适应蝗虫算法 IGOA-ALOL 与稀疏正则化的结构损伤识别新方法,以实现结构状态稀疏正则化评估。IGOA-ALOL 在传统蝗虫算法基础上引入了自适应 Lévy 飞行和精英反向学习策略。CEC 基准函数测试、简支梁数值算例和实验结构工况识别验证了所提方法具有精确的识别精度和良好的噪声鲁棒性。具体结论如下。

(1) 蝗虫算法在结构损伤识别领域直接应用的识别精度较差,需要引入新的策略以提高种群的多样性以及全局收敛性,从而满足不同损伤工况的识别精度要求;在本文考虑改进策略中,同时结合自适应 Lévy 飞行策略和精英反向学习策略的 IGOA-ALOL 具有最高的结构损伤识别精度。

(2) 在不同的损伤工况和测量不确定性影响下,本文所提融合 IGOA-ALOL 与稀疏正则化的结构损伤识别方法能够有效地提高结构损伤识别精度和噪声鲁棒性,具有一定的实际结构应用潜力。

(3) 实验室方管截面梁实验结果验证了本文所提方法应用于实际结构的有效性。不完备振型测量条件下的结构损伤识别结果表明,本文方法在仅获得一半竖向自由度的振型信息的情况下仍可以提供准确的结构损伤识别结果。

参考文献(References):

- [1] Li H, Ou J P. Structural health monitoring: From sensing technology stepping to health diagnosis[J]. *Procedia Engineering*, 2011, **14**: 753-760.
- [2] Worden K, Farrar C R, Manson G, et al. The fundamental axioms of structural health monitoring[J]. *Proceedings; Mathematical, Physical and Engineering Sciences*, 2007, **463**(2082): 1639-1664.
- [3] 王凌波,王秋玲,朱 钊,等.桥梁健康监测技术研究现状及展望[J]. *中国公路学报*, 2021, **34**(12): 25-45. (WANG Lingbo, WANG Qiuling, ZHU Zhao, et al. Current status and prospects of research on bridge health monitoring technology[J]. *China Journal of Highway and Transport*, 2021, **34**(12): 25-45. (in Chinese))
- [4] 《中国公路学报》编辑部.中国桥梁工程学术研究综述·2021[J]. *中国公路学报*, 2021, **34**(2): 1-97. (Editorial Department of China Journal of Highway and Transport. Review on China's bridge engineering research: 2021[J]. *China Journal of Highway and Transport*, 2021, **34**(2): 1-97. (in Chinese))
- [5] Li H, Ou J P. The state of the art in structural health monitoring of cable-stayed bridges[J]. *Journal of Civil Structural Health Monitoring*, 2016, **6**(1): 43-67.
- [6] 丁政豪,吕中荣,刘济科.基于多种搜索策略的人工蜂群算法的结构损伤识别[J]. *计算力学学报*, 2016, **33**(5): 791-795. (DING Zhenghao, LÜ Zhongrong, LIU Jike. Structural damage identification based on ABC algorithm with variable search strategy[J]. *Chinese Journal of Computational Mechanics*, 2016, **33**(5): 791-795. (in Chinese))
- [7] 余 岭,徐 鹏.基于 CACO 算法的结构多损伤识别[J]. *振动工程学报*, 2010, **23**(5): 523-529. (YU Ling, XU Peng. A CACO-based algorithm for structural multi-damage identification[J]. *Journal of Vibration Engineering*, 2010, **23**(5): 523-529. (in Chinese))
- [8] Chen Z P, Yu L. A novel PSO-based algorithm for structural damage detection using Bayesian multi-sample objective function[J]. *Structural Engineering & Mechanics*, 2017, **63**(6): 825-835.
- [9] 余 岭,万祖勇,朱宏平.基于宏观调控策略的结构损伤检测 PSO 改进算法[J]. *计算力学学报*, 2008, **25**(1): 14-19. (YU Ling, WAN Zuyong, ZHU Hongping. An improved PSO algorithm for structural damage detection based on macro-economic control strategy[J]. *Chinese Journal of Computational Mechanics*, 2008, **25**(1): 14-19. (in Chinese))
- [10] Yu L, Xu P. Structural health monitoring based on continuous ACO method[J]. *Microelectronics Reliability*, 2011, **51**(2): 270-278.
- [11] 黄天立,楼梦麟,任伟新.基于 CMDLAC 指标和遗传算法的结构损伤定位研究[J]. *计算力学学报*, 2009, **26**(4): 529-534. (HUANG Tianli, LOU Menglin, REN Weixin. Structural damage localization based on the CMDLAC and genetic algorithm[J]. *Chinese Journal of Computational Mechanics*, 2009, **26**(4): 529-534. (in Chinese))
- [12] 周宏元,张广才,王小娟,等.基于改进蝴蝶优化算法的结构损伤识别[J]. *振动测试与诊断*, 2023, **43**(1): 164-171, 204. (ZHOU Hongyuan, ZHANG Guang-

- cai, WANG Xiaojuan, et al. Structural damage identification based on improved butterfly optimization algorithm[J]. *Journal of Vibration, Measurement & Diagnosis*, 2023, **43**(1): 164-171, 204. (in Chinese))
- [13] Saremi S, Mirjalili S, Lewis A. Grasshopper optimization algorithm: Theory and application[J]. *Advances in Engineering Software*, 2017, **105**: 30-47.
- [14] Jamil M, Mittal S. Hourly load shifting approach for demand side management in smart grid using grasshopper optimisation algorithm[J]. *IET Generation, Transmission & Distribution*, 2020, **14**(5): 808-815.
- [15] Yazdani R, Taghipourian M J, Pourpasha M M, et al. Attracting potential customers in E-commerce environments: A comparative study of metaheuristic algorithms[J]. *Processes*, 2022, **10**(2): 369.
- [16] Zhang J Q, Zhang J, Zhong M, et al. A GOA-MSVM based strategy to achieve high fault identification accuracy for rotating machinery under different load conditions[J]. *Measurement*, 2020, **163**: 108067.
- [17] Tizhoosh H R. Opposition-based learning: A new scheme for machine intelligence[J]. *IEEE*, 2005, **1**: 695-701.
- [18] Ding Z H, Hou R R, Xia Y. Structural damage identification considering uncertainties based on a Jaya algorithm with a local pattern search strategy and L0, 5 sparse regularization[J]. *Engineering Structures*, 2022, **261**: 114312.
- [19] 雷勇志, 黄民水, 顾箭峰, 等. 环境温度影响下基于支持向量机与强化飞蛾扑火优化算法的结构稀疏损伤识别[J]. *计算力学学报*, 2022, **39**(2): 170-177. (LEI Yongzhi, HUANG Minshui, GU Jianfeng, et al. Structural sparse damage identification considering ambient temperature variations based on support vector machine and enhanced moth-flame optimization[J]. *Chinese Journal of Computational Mechanics*, 2022, **39**(2): 170-177. (in Chinese))
- [20] Chen Z P, Zhao D, Chen Z, et al. Structural damage detection based on modal feature extraction and multi-objective optimization method for steel structures[J]. *Frontiers in Materials*, 2022, **9**: 1015322
- [21] Pan C D, Yu L, Chen Z P, et al. A hybrid self-adaptive Firefly-Nelder-Mead algorithm for structural damage detection[J]. *Smart Structures and Systems*, 2016, **17**(6): 957-980.

An adaptive grasshopper algorithm for sparse-regularization-based structural damage assessment

LIU Qitian, CHEN Zepeng*, YANG Xinhua, CHEN Zhou

(School of Civil Engineering and Transportation, Foshan University, Foshan 528225, China)

Abstract: Structural condition assessment is crucial for ensuring the safe services of structures, with structural damage detection (SDD) being a core component. In this paper, a novel SDD method is proposed based on the adaptive grasshopper algorithm and sparse regularization. It aims to tackle accuracy decline of SDD results and instability involving uncertainties and incomplete measurement, thereby achieving sparse-regularization-based structural condition assessment. Firstly, adaptive Lévy flight and elite opposition-based learning strategies are incorporated into the adaptive grasshopper algorithm to prevent the SDD process from falling into local optima and to enhance the stability of SDD results. Secondly, a modal parameter-based objective function with sparse regularization is formulated to increase the sparsity of SDD results, thereby improving SDD accuracy and robustness. The optimization results of competition-based evolutionary computation benchmark functions show that the adaptive grasshopper algorithm exhibits better global convergence and identification stability compared with its standard version. Numerical and experimental results for simply-supported beams indicate that the proposed method can ensure reliable SDD accuracy even in the case of incomplete measurements, and it possesses good noise robustness as well.

Key words: structural condition assessment; structural damage detection; adaptive grasshopper algorithm; sparse regularization; incomplete measurement