

基于分形理论的螺栓连接松动状态识别研究*

张小丽, 王芳珍, 王永强, 梁旺, 范攀峰, 罗鑫

(长安大学道路施工技术与装备教育部重点实验室 西安, 710064)

摘要 航空发动机转子系统拉杆螺栓连接结构复杂,其振动信号含有复杂非线性成分,而时频分析方法需将系统进行线性化假设,很难分析其非线性成分特征。针对此问题,采用了单重分形方法。首先,计算不同状态信号的先验数据关联维数,建立先验区间;其次,计算未知状态的关联维数从而完成归类;最后,通过经典 Lorenz 仿真系统和航空发动机转子螺栓连接结构的松动状态识别对该方法进行验证。结果表明,传统 GP(Grassberger-Procaccia,简称 GP)算法求取关联维数时需对无标度区间进行人为选取,造成选取结果的主观性和随机性,采用密度峰值聚类算法进行优化可实现无标度区间的自适应选取,提升识别准确率。

关键词 螺栓连接状态识别;分形理论;非线性系统;密度峰值聚类算法;GP 算法

中图分类号 TH133

0 引言

航空发动机转子系统的螺栓连接结构关系着发动机甚至整个飞行器的安全,其连接状态的准确识别对于消除发动机安全隐患至关重要^[1]。螺栓连接结构状态识别研究基本是基于线性理论开展的,只能在不考虑或仅考虑微弱非线性成分的条件下完成状态识别,难以对信号完整特征进行提取。目前,常用的螺栓连接状态检测方法有基于信号特征分析方法、基于有限元法和基于数据驱动方法。

基于信号特征分析法是根据螺栓连接松动时,连接结构的预紧力等参数产生变化,经过数据处理提取信号的特征值并与理论特征值进行比较,从而完成状态的识别。王九龙等^[2]利用短时傅里叶变换(short-time Fourier transform,简称 STFT)方法得到不同预紧状态的特征,并提出 STFT-IP 特征指标表征不同连接状态,实现了螺栓连接状态的识别。Wang 等^[3]通过建立螺栓轴向预紧力与能量耗散之间的关系,对松动程度进行定量监测。但是,基于信号特征分析的前提是将螺栓连接结构假设为线性化系统,其非线性成分特征提取困难。

有限元法应用广泛,可合理地处理并发掘非线性特性。胡阳等^[4]采用有限元模型分析螺栓松动过程接触状态与残余预紧力的变化规律,认为螺纹接触面的滑移状态是影响剪切刚度的主要因素。Liu

等^[5]采用三维有限元模型研究疲劳断裂的原因,认为螺栓松动主要是由两固支板之间的相对运动引起的。但是,螺栓连接结构在复杂工况和多种激励情况下的非线性成分复杂,有限元法也很难准确建立动力学模型对其连接状态进行分析。

随着信息技术的高速发展,基于数据驱动的机械设备智能检测方法得到了广泛应用并取得了较高的准确率。其中,依靠数据驱动的机器学习方法有概率神经网络^[6]、支持向量机^[7]、决策树^[8]及 K 近邻法^[9],深度学习方法包括卷积神经网络^[10]和长短期记忆网络^[11]。陈仁祥等^[12]将原始振动信号输入到卷积神经网络中,实现了变转速条件下风机基础的螺栓状态检测。Pal 等^[13]通过卷积神经网络从基于振动的时频扫描图像中提取判别特征,识别出不同的螺栓连接状态。基于数据驱动的识别方法训练过程复杂且训练时间较长,对样本要求较高,而“黑箱”问题限制了其在医疗、航空等安全性要求严苛领域的应用^[14]。

基于分形理论的故障诊断方法主要通过提取时序信号的分形特征完成故障分类^[15-17],其将高维非线性动态系统在低维空间进行重构,从而对螺栓的非线性系统进行简化,使得信号中所提取的特征值更具鲁棒性和敏感性,适合于研究复杂的非线性系统,但其在螺栓连接状态识别方面的应用较少^[18]。笔者将分形理论应用于螺栓连接状态的识别,根据

* 陕西省自然科学基金基础研究计划资助项目(2021JM-169)

收稿日期:2023-09-19;修回日期:2024-03-11

关联维数简单、对时间序列变化敏感的特点,选择其作为计算指标。采用的主要计算方法为GP算法^[19-20],由于其无标度区间需要人为选取,会给结果带来较大的误差和随机性,因此对该算法进行了改进,使其能够自动识别无标度区间进而得到更加准确的关联维数,更好地实现螺栓连接状态的识别。

1 理论基础

1.1 分形概述

分形几何学^[21]主要面向无序和非规则现象,可以处理不易定量描述的复杂动力学问题。在故障诊断领域,分形理论的应用场景包括:①设备主要运动为摩擦时,采集运行过程中所产生的磨屑和切屑,计算其分形特征值,从而判断设备的运行状态;②设备主要运动为旋转时,采集运行过程中的振动信号并计算其分形特征值,进而确定机械是否处于故障状态。因螺栓连接结构的切屑不易获取,因此本研究采集螺栓连接结构的振动信号并计算其分形维数,实现对设备连接状态的识别。

若机械设备发生故障,所采集的振动信号往往包含非平稳等动态特性,导致基于时频分析的方法对于信号的识别与特征值提取困难。分形理论只需对振动信号进行分析,计算其分形特征值便能够将信号直观地进行分类。其中,与多重分形相比,单重分形具有计算量小、诊断效率高和可靠性高等特点,便于实现状态的快速识别。分形维数的计算方式中,由于关联维数能够敏感地捕捉时序信号的变化,因此本研究采用以关联维数为计算指标的单重分形方法。

1.2 GP算法求取关联维数的过程

GP算法通过在高维空间中重构振动信号,使其高维空间特征更加全面,进而计算振动信号的关联维数值,其过程如下。

首先,对确定的非平稳时间序列 $\{x(i), i=1, 2, \dots, n\}$ 采用延迟坐标法重构 m 维相空间中的点,即

$$X(i)=[x(i), x(i+\tau), \dots, x(i+(m-1)\tau)] \quad (1)$$

$$[(i=1, 2, \dots, N)]$$

其中: τ 为延迟时间; m 为嵌入维数; N 为高维相空间的相点数量, $N=n-(m-1)\tau$ 。

其次,计算重构后相空间满足间距小于半径相

点的数量,并计算关联积分 $C(m, r)$,即

$$C(m, r) = \frac{2}{N(N-1)} \sum_{i \neq j}^N H(r - \|X(i) - X(j)\|) \quad (2)$$

其中: r 为相对距离半径; i, j 为点的个数; $H(\cdot)$ 为Heaviside阶跃函数。

关联积分反映了相空间 $X(i)$ 中相点距离小于半径 r 的概率。关联积分和关联维数的关系为 $C(m, r) \propto r^{D(m)}$,关联维数会随着嵌入维数的增加而趋于稳定值。研究对象的分形维数 D_2 为

$$D_2 = \lim_{m \rightarrow \infty} \lim_{r \rightarrow 0} \frac{\ln C(m, r)}{\ln r} \quad (3)$$

在双对数坐标图中,根据研究对象绘制 $\ln r - \ln C(m, r)$ 曲线,其中线性拟合度最好的区域对应无标度区间。无标度区间示意图如图1所示。图中实线为双对数关联积分曲线,虚线为确定无标度区间后的最小二乘拟合直线,关联维数值即为该直线斜率。




图1 无标度区间示意图

Fig.1 Schematic diagram of the scale-free interval

传统的无标度区间选取方法为主观识别法,通过人为观察确定线性拟合最优的区域。这种方法增加了结果的不确定性,需要一种客观自主的无标度区间识别方法来准确提取关联维数。

1.3 密度峰值聚类算法

密度峰值聚类算法(density peak clustering, 简称DPC)^[22]可以处理包括非球形聚类在内的各种形状的簇类。该算法基于以下假设:①密度较高的聚类中心被密度较低的数据点所围绕;②相邻聚类中心相对较远。

在计算 x_i 和 x_j 的距离时,一般采用欧几里得距离,计算得到的距离 d_{ij} 可表示为

$$d_{ij} = \text{dist}(x_i, x_j) \quad (4)$$

以截断距离 d_c 计算样本 x_i 的局部密度,即

$$\rho_i = \sum_{i,j \neq 1} \exp \left(- \left(\frac{d_{ij}}{d_c} \right)^2 \right) \quad (5)$$

其中: ρ 为局部密度; d_c 为数据点 i 的邻域截断距离。

数据点之间的相对距离 δ 的计算公式为

$$\begin{cases} \delta_i = \min(d_{ij}) & (\rho_i \neq \max(\rho)) \\ \delta_i = \max(d_{ij}) & (\rho_i = \max(\rho)) \end{cases} \quad (6)$$

根据数据的局部密度和相互之间的欧几里得距离,绘制出基于局部密度和相对距离的DPC聚类中心决策示意图,如图2所示。其中,横、纵坐标局部密度与相对距离均为量纲为1的量。由图可知,数据点1和10可确定为聚类中心。




图2 基于局部密度和相对距离的DPC聚类中心决策示意图
Fig.2 DPC cluster-center decision diagram based on local density and relative distance

2 无标度区间自动识别算法及仿真信号验证分析

2.1 基于DPC的改进GP算法流程

为了提升GP方法在确定关联维数时对无标度区间识别的精确性,降低因人为选择带来的不确定性,本研究提出一种经过DPC优化处理的GP算法(DPC-GP),其主要步骤如下。

1) 将观测到的信号变化从待测动态系统中提取出来,并将其表示为一个独立的时间序列变量。

2) 在处理时间序列 $\{x_1, x_2, \dots, x_n\}$ 数据时,采用饱和关联维数法来测定嵌入维数 $m (m \in \mathbb{Z}^+)$ 。通过逐步增加嵌入维数,观察对数图中的密集程度变化,直到变化不再显著,以此来确定最佳的嵌入维数,同时利用互信息法来确定延迟时间 τ 。

3) 为获取时序信号在高维空间中的信息,通过相空间重构将时序信号转换到高维空间内,再确定延迟时间后得到的 $X_i = [x_i, x_{i+\tau}, \dots, x_{i+(m-1)\tau}]$, $i = 1, 2, \dots, N$ 。

4) 通过GP算法计算高维空间的相点,得到点

集 $\{\ln(r_i), \ln C(r_i), \dots\}$, $i = 1, 2, \dots, N$ 。对这些双对数坐标下的数据执行二阶差分运算,形成一个新的集合 $T_1 = \{\ln C(r_i)''\}$, $i = 1, 2, \dots, M$ 。其中 $r(i) \in [\ln r_{\min}, \ln r_{\max}]$, $r_{\min}, r_{\max}$ 分别为重构相空间后两点的最小和最大距离。

5) 采用DPC算法对 T_1 进行聚类分析,仅保留零周围的数据点并标记为 T_2 ,这是因为在无标度区间内的一阶差分为常数,二阶差分接近于零,其他区域的数据均须剔除。

6) 从 T_2 集合中移除那些较大的误差数据点,以便更准确地确定新的集合 T_3 。

7) 对数据集 T_3 中多段接近零的区域所对应的双对数曲线图进行相关性检验并保留最接近1的区间,进行最小二乘拟合后得到关联维数值。

DPC-GP算法流程如图3所示。




图3 DPC-GP算法流程图

Fig.3 Flowchart of DPC-GP algorithm

2.2 Lorenz 系统仿真信号验证分析

Lorenz 混沌系统是一种非线性动力系统,该系统的关联维数参考理论值为 2.05 ± 0.01 ,可以用于测试关联维数计算方法的精确度。其表达式为

$$\begin{cases} \frac{dx}{dt} = \sigma(y - x) \\ \frac{dy}{dt} = x(R - z) - y \\ \frac{dz}{dt} = xy - bz \end{cases} \quad (7)$$

采用四阶龙格-库塔法对式(7)求解,设定参数为: $\sigma=16$, $R=45.92$, $b=4$,起始点为 $[-1, 0, 1]$,迭代步长为 0.01 s。对 x 轴方向 5 000 长的数据进行分析,得到 Lorenz 吸引子相轨迹图如图4所示。Lorenz 吸引子 x 方向时序投影如图5所示。




图 4 Lorenz 吸引子相轨迹图
Fig.4 Lorenz attractor phase trajectory diagram




图 5 Lorenz 吸引子 x 方向时序投影
Fig.5 Lorenz attractor x -direction time series projection

首先,计算时序的延迟时间 τ ,通过自相关法可得 $\tau=10\text{ s}$;其次,利用饱和关联维数法确定最佳嵌入维数 m 。将 m 从2开始以2为步长一直增加到30,观察双对数曲线的密集程度变化情况。当曲线密集程度不再发生明显变化,这时的 m 值即为最佳嵌入维数。Lorenz 双对数图如图6所示。由图可知, $m=12$ 即为最佳嵌入维数。当 $\ln(r)$ 较小时曲线相对不规则,而当 $\ln(r)$ 较大时曲线趋于收敛。中间区域呈斜直线,为无标度区间,对区间的点进行最小二乘拟合可得到相应的关联维数值。因为无标度区间直接影响到关联维数值的计算结果,因此该区间的选择至关重要。




图 6 Lorenz 双对数图
Fig.6 Lorenz double logarithmic plot

若采用人为选取方法选择无标度区间,选取结果具有很大的随机性,从而造成较大的误差。本研究采用DPC方法二阶差分后的数据点进行聚类分析,自适应地选取无标度区间,消除了人为选取的随机性。

二阶差分点分布图如图7所示。由图可见,数据主要分布于红框、黑框和绿框区域范围内,分别代表大于零、零附近和小于零的点集,因此聚类中心个数初步认定为3。




图 7 二阶差分点分布图
Fig.7 Second-order difference point distribution

为了确定聚类中心的个数,绘制 Lorenz 系统二阶差分点集的 DPC 聚类中心决策图,如图8所示。由图可知,有3个样本点在局部密度 ρ 和相对距离 δ 上较突出,可被视为潜在的聚类中心。因此,聚类中心点设定为3。




图 8 Lorenz 系统二阶差分点集的 DPC 聚类中心决策图
Fig.8 DPC cluster-center decision graph for the second-order difference point set of the Lorenz system

经过DPC方法差分后的聚类效果如图9所示。其中,不同颜色表示不同的聚类类别。由图可知,尽管二阶差分点按照聚类被划分为3个区域,但是仍存在一些如图中红圈标记的误差点。这些误差点与




图 9 聚类效果图
Fig.9 Clustering effect diagram

其他区间分割且往往具有较短的区间长度,需进行人工剔除。经过分类后会出现有多个区间段,此时采取相关性检验,最接近 1 的区间段即为最佳无标度区间。

对最佳无标度区间内的数据点以嵌入维数作为变量执行最小二乘拟合,得到相应的关联维数,并将所得曲线与 GP 算法所得曲线进行对比。关联维数精度对比如图 10 所示。由图可知,关联维数会随着嵌入维数的增加而增加,当 $m=12$ 时趋于稳定,此时即为最佳嵌入维数和关联维数。经过自适应选取无标度区间的 DPC-GP 算法明显优于传统 GP 算法,其计算的关联维数值更接近理论参考值。




图 10 关联维数精度对比图

Fig.10 Comparison plot of correlation dimension accuracy

本研究比较了不同方法求解 Lorenz 系统关联维数的结果。不同方法求取的关联维数值见表 1。由表可知,主观识别法和 k-means 法计算的关联维数误差较大,所提出的 DPC-GP 算法得到的关联维数更接近理论参考值 2.05 ± 0.01 ,误差范围在 $0.3\% \sim 0.67\%$ 之间,结果更为精确。

表 1 不同方法求取的关联维数值

Tab.1 Different methods to find the value of correlation dimension

方法	数值
主观识别法	2.100 ± 0.061
k-means 法	2.381
DPC-GP 算法	2.046

3 航空发动机转子螺栓连接松动故障实验分析

3.1 航空发动机转子螺栓连接实验台

为了对所提方法进行验证,建立某型航空发动机高压转子系统实验平台,实验设备包括航空发动机高压转子(盘鼓型)、ICP 加速度传感器、JZK-5 模态激振器和索尼 EX 数据采集仪。其中,高压转子结

构由周向均匀分布的 24 个拉杆螺栓将 9 根不可拆卸的封严篦齿盘进行压紧连接而成,转子结构扭矩通过压紧面的摩擦力进行传递。传感器安装及敲击角度示意图如图 11 所示,其中数字代表传感器编号。拉杆螺栓分布如图 12 所示,其中数字代表螺栓编号。




图 11 传感器安装及敲击角度示意图

Fig.11 Schematic diagram of sensor installation and knocking angle




图 12 转子拉杆螺栓分布图

Fig.12 Schematic distribution of rotor tie rod bolts

转子螺栓的 4 种连接状态见表 2,以模拟不同程度的螺栓松动状态。实验通过敲击 A-A 截面中 26

表 2 转子螺栓的 4 种连接状态

Tab.2 Four connection states for rotor bolting

装配紧度状态	简要说明
1	整体标准预紧(24 个螺栓全部标准预紧)
2	局部轻微松动(1~12 号螺栓标准预紧后旋松 1 圈,其余螺栓标准预紧)
3	整体轻微松动(1~24 号螺栓标准预紧后全部旋松 1 圈)
4	整体严重松动(1~24 号螺栓标准预紧后全部旋松 3 圈)

号传感器方向对系统进行激振测试,激振器以方波、1 Hz、0.75 A 的工况进行工作,通过 6.4 kHz 的采样频率进行采样,得到不同连接状态下的振动信号。

3.2 基于 DPC-GP 算法计算关联维数的螺栓连接松动状态识别

由于 4 种连接状态下的系统特性非常接近,因此其在时频域的图像非常相似。4 种连接状态的时域及其频谱图如图 13 所示。




图 13 4 种连接状态的时域及其频谱图

Fig.13 Time-domain plots and spectrograms of the four connection states

由图 13 中时域图可以看出,随着转子螺栓松动程度的加剧,整体波动较小,变化不大,规律性也不强;由频谱图可以看出,频率成分复杂,分离困难。这是因为周向分布的螺栓受力不均,阻尼和刚度产生非线性变化,导致其信号中包含非线性特征,传统的时频方法较难适应,而采用分形理论进行连接状

态的识别可以避免其在时频域分析中的不利影响。

首先,通过互信息法计算延迟时间,将 τ 分别设置为 24、21、24 和 20 s;其次,采用饱和关联维数法进行嵌入维数的选择,将嵌入维数 m 从 1 开始,以 1 为步长一直增加到 15;最后,得到 4 种连接状态下双对数图及其关联维数图,如图 14 所示。




图 14 4 种连接状态下双对数图及其关联维数图

Fig.14 Double logarithmic graphs and their associated dimensional graphs in four connection states

由前述可知,当双对数图的密集程度不再有明显变化时的嵌入维数即为最佳嵌入维数值,最小二乘拟合曲线的斜率即为关联维数,而此时通过 DPC-GP 算法求取的关联维数也趋于稳定。以图 14(a)为例,随着嵌入维数的增加,双对数曲线开始由不规则的蓝线区域逐渐进入无标度区间内,当 $m=11$ 时,曲线已较密集且不再明显增加,此时关联维数收敛至 0.487 4。同理,局部轻微松动、整体

轻微松动和整体严重松动条件下的局部最佳嵌入维数分别为 11、10 和 9,各螺栓连接状态的关联维数分别为 0.224 3、0.281 9 和 0.323 5。

从不同状态下的先验数据中各随机挑选 10 组,以同样方法进行数据处理后得到相应的关联维数值,再对该 10 个关联维数值求取均值 $\overline{D_c}$ 和误差 e (e 为该关联维数值与均值的最大差值的绝对值)。不同状态信号的关联维数值见表 3。

按照 $S_i=[\overline{D_c}-e, \overline{D_c}+e]$ 即可建立不同连接状态的先验区间 $\{S_i\}, i=0, 1, 2, 3$ 。对未知状态求取关联维数后有且仅有一个先验区间符合要求,否则无法完成分类,因此先验区间之间必须相互独立。由表 3 可知,经过求取先验数据后 4 种连接状态的先验区间虽然较接近但并无交集,满足相互独立的条件。此外还可以看出,局部轻微松动的关联维数区间为 $[0.204\ 5, 0.249\ 7]$,整体轻微松动的关联维数区间为 $[0.264\ 1, 0.298\ 7]$,二者区间比较接近。这是因为这 2 种连接状态下松动变化很小,因此其关联维数值非常接近,但单重分形仍能很好地进行区分。

表 3 不同状态信号的关联维数值
Tab.3 Correlation dimension values for different state signals

状态类型	$\overline{D_c}$	e
整体标准预紧	0.495 4	0.030 0
局部轻微松动	0.227 1	0.022 6
整体轻微松动	0.281 4	0.017 3
整体严重松动	0.343 7	0.023 0

为了对方法进行验证,从未知连接状态的数据中随机挑选 3 种连接状态的数据进行关联维数的求取,对其松动状态进行识别。为了避免偶然性,每种连接状态挑选 3 组数据,根据得到的平均值与先验区间进行对比归类。将顺序打乱,关联维数均值结果记为 $\{\overline{D_i^*}\}, i=1, 2, 3$ 。未知状态信号的关联维数值见表 4。

由表 4 可知,无论是采用单个数据还是使用均值与先验区间进行对比,都能得到以下结果:

表 4 未知状态信号的关联维数值
Tab.4 Correlation dimension values for unknown state signals

状态类别	数据 1	数据 2	数据 3	$\overline{D_i^*}$
未知状态 1	0.345 7	0.328 6	0.351 5	0.341 9
未知状态 2	0.216 2	0.231 4	0.244 8	0.230 8
未知状态 3	0.288 5	0.276 9	0.284 6	0.283 3

$\overline{D_1^*} \in S_3, \overline{D_2^*} \in S_1, \overline{D_3^*} \in S_2$, 即未知状态 1 为整体严重松动,未知状态 2 为局部轻微松动,未知状态 3 为整体轻微松动。经验证,识别结果正确。因此,通过先验数据建立先验区间后求取未知状态的关联维数值进行归类,可以完成不同螺栓连接状态的识别。

4 结 论

1) 单重分形通过获取时间序列的关联维数值对系统状态进行表征。首先计算先验数据关联维数建立先验区间,然后求取未知状态的关联维数完成螺栓连接状态的识别,可以定量地判断螺栓连接状态,直观且高效。识别结果表明,所提方法对于状态相近的整体轻微松动和局部轻微松动也能准确识别,验证了方法的有效性。

2) 基于 DPC 改进的 GP 算法通过对二阶差集合进行聚类分析,完成了无标度区间的自适应选取,减少了人为选取的随机性,进而得到更加准确的关联维数。

3) 采用单重分形的航空发动机转子螺栓连接状态识别方法虽然能够对不同的松动状态进行有效识别,但需要建立先验区间,还存在对故障信号的样本要求较高、计算较为烦琐的问题。

参 考 文 献

- [1] JIANG T, WU Q, WANG L, et al. Monitoring of bolt looseness-induced damage in steel truss arch structure using piezoceramic transducers[J]. IEEE Sensors Journal, 2018, 18(16): 6677-6685.
- [2] 王九龙,盛俊杰,蒋家勇,等.STFT-IP 时频特征提取技术的螺栓松动识别方法[J]. 噪声与振动控制, 2021, 41(3):108-112.
WANG Jiulong, SHENG Junjie, JIANG Jiayong, et al. Identification method of bolt looseness using STFT-IP time-frequency feature extraction technology[J]. Noise and Vibration Control, 2021,41(3):108-112.(in Chinese)
- [3] WANG F, HUO L, SONG G. A piezoelectric active sensing method for quantitative monitoring of bolt loosening using energy dissipation caused by tangential damping based on the fractal contact theory[J]. Smart Materials and Structures, 2018, 27(1): 015023.
- [4] 胡阳,姜东,王旻睿,等.横向载荷作用下螺栓连接松动过程研究[J]. 振动、测试与诊断,2020,40(6):1091-1098.
HU Yang, JIANG Dong, WANG Minrui, et al. Study on loosening process of bolted joints under transverse load [J]. Journal of Vibration, Measurement & Diagnosis, 2020,40(6):1091-1098.(in Chinese)
- [5] LIU Z, YAN X, ZHENG M, et al. The effect of tightening again on bolt loosening under transverse

- load: Experimental and finite element analysis[J]. Structures, 2022, 44: 1303-1311.
- [6] 李文业, 杨帆, 周亚星, 等. 基于改进 EMD 与 PNN 的汽轮机通流部分故障诊断[J]. 振动、测试与诊断, 2018, 38(6): 1138-1142.
- LI Wenye, YANG Fan, ZHOU Yaxing, et al. Research on fault diagnosis of steam turbine flow passage based on improved EMD and PNN[J]. Journal of Vibration, Measurement & Diagnosis, 2018, 38(6): 1138-1142.(in Chinese)
- [7] 王保建, 张小丽, 傅杨奥骁, 等. 优化支持向量机及其在智能故障诊断中的应用[J]. 振动、测试与诊断, 2017, 37(3): 547-552.
- WANG Baojian, ZHANG Xiaoli, FUYANG Aoxiao, et al. Optimization of support vector machine and its application in intelligent fault diagnosis[J]. Journal of Vibration, Measurement & Diagnosis, 2017, 37(3): 547-552.(in Chinese)
- [8] LI G, CHEN H, HU Y, et al. An improved decision tree-based fault diagnosis method for practical variable refrigerant flow system using virtual sensor-based fault indicators[J]. Applied Thermal Engineering, 2018, 129: 1292-1303.
- [9] 石明宽, 赵荣珍. 基于局部质心均值最小距离鉴别投影的旋转机械故障数据降维分析研究[J]. 振动工程学报, 2021, 34(2): 421-430.
- SHI Mingkuan, ZHAO Rongzhen. Dimensional reduction analysis of rotating machinery fault data based on local centroid mean minimum-distance discriminant projection [J]. Journal of Vibration Engineering, 2021, 34(2): 421-430.(in Chinese)
- [10] LIU P, WANG X, CHEN T, et al. Research on a percussion-based bolt looseness identification method based on phase feature and convolutional neural network [J]. Smart Materials and Structures, 2023, 32(3): 035010.
- [11] 池永为, 杨世锡, 焦卫东. 基于 LSTM-RNN 的滚动轴承故障多标签分类方法[J]. 振动、测试与诊断, 2020, 40(3): 563-571.
- CHI Yongwei, YANG Shixi, JIAO Weidong. A multi-label fault classification method for rolling bearing based on LSTM-RNN [J]. Journal of Vibration, Measurement & Diagnosis, 2020, 40(3): 563-571.(in Chinese)
- [12] 陈仁祥, 徐培文, 韩坤林, 等. 多尺度一维卷积神经网络的风机基础螺栓松动智能检测[J]. 振动与冲击, 2022, 41(22): 301-307.
- CHEN Renxiang, XU Peiwen, HANG Kunlin, et al. Intelligent looseness detection for bolts of a fan foundation based on a multi-scale one-dimensional convolutional neural network [J]. Journal of Vibration and Shock, 2022, 41(22): 301-307.(in Chinese)
- [13] PAL J, SIKDAR S, BANERJEE S. A deep-learning approach for health monitoring of a steel frame structure with bolted connections[J]. Structural Control and Health Monitoring, 2022, 29(2): e2873.
- [14] 曾春艳, 严康, 王志锋, 等. 深度学习模型可解释性研究综述[J]. 计算机工程与应用, 2021, 57(8): 1-9.
- ZENG Chunyan, YAN Kang, WANG Zhifeng, et al. Survey of interpretability research on deep learning models [J]. Computer Engineering and Applications, 2021, 57(8): 1-9.(in Chinese)
- [15] YU M, FANG M, CHEN W, et al. Compound faults feature extraction of inter-shaft bearing based on vibration signal of whole aero-engine [J]. Journal of Vibration and Control, 2023, 29(1/2): 51-64.
- [16] CHEN G, YAN C, MENG J, et al. Health condition monitoring of bearings based on multifractal spectrum feature with modified empirical mode decomposition-multifractal detrended fluctuation analysis [J]. Structural Health Monitoring, 2022, 21(6): 2618-2640.
- [17] 樊佳, 齐咏生, 高学金, 等. 基于形态学多重分形的风电机组轴承故障诊断[J]. 振动、测试与诊断, 2021, 41(6): 1081-1089.
- FAN Ji, QI Yongsheng, GAO Xuejin, et al. Fault diagnosis of wind turbine bearing based on morphological multi-fractal analysis [J]. Journal of Vibration, Measurement & Diagnosis, 2021, 41(6): 1081-1089.(in Chinese)
- [18] 余坚, 谢寿生, 任立通, 等. 拉杆转子装配振动检测分形研究[J]. 振动与冲击, 2014, 33(14): 84-88.
- YU Jian, XIE Shousheng, REN Litong, et al. Fractal research on the assembly vibration detection of rod fastening rotor [J]. Journal of Vibration and Shock, 2014, 33(14): 84-88.(in Chinese)
- [19] ZHANG S, HUANG Z. Fractal analysis of the relation between the observation scale and the prediction cycle in short-term traffic flow prediction [J]. International Journal of Intelligent Transportation Systems Research, 2019, 17(1): 1-8.
- [20] 王永强. 基于分形理论的螺栓连接松动状态识别研究 [D]. 西安: 长安大学, 2023.
- [21] 刘伟强. 分形理论在故障诊断中的应用研究 [D]. 长沙: 国防科技大学, 2018.
- [22] RODRIGUEZ A, LAIO A. Clustering by fast search and find of density peaks [J]. Science, 2014, 344(6191): 1492-1496.



第一作者简介: 张小丽, 女, 1983 年 10 月生, 博士, 副教授。主要研究方向为机械设备状态监测。曾发表《机械重大装备寿命预测综述》(《机械工程学报》2011 年第 11 期) 等论文。
E-mail: lilyzhang@chd.edu.cn