

DOI: 10.19650/j.cnki.cjsi.J2210129

基于 K-medoids 分类的场地微振动振源识别方法*

张钧奕, 余才志, 王 鹏, 孙长库

(天津大学精密测试技术及仪器国家重点实验室 天津 300072)

摘 要: 各类精密实验室及半导体生产厂房都具有隔振设计, 但周围仍可能出现一些超限振动, 为找到经隔振设施后转变为微振动的干扰源, 需对检测信号进行微振盲源分类与识别; 因瞬态微振动信号低频、低幅值、持续时间短的特性, 传统振动信号分析手段很难解决此问题, 因此本文提出一种基于 K-medoids 分类的场地微振动振源识别方法。将长期监测数据通过预处理后进行端点检测算法截取瞬态微振动信号; 对提取到的信号进行归一化梅尔滤波系数特征提取, 构成特征矩阵; 将特征矩阵进行基于动态时间归整距离的 K-medoids 算法聚类, 并对场地周围包含的振源数进行估计; 对各分类结果进行混合高斯模型建模, 采集怀疑振源的数据, 并由模型概率阈值判断识别, 找出影响严重的干扰源。利用某场地 24 h 长期监测数据进行实验, 成功找到该场地平均幅值最大和出现频次最高的两类干扰振源, 分类正确率达到 90.57%, 识别率达到 96.8%, 证明了本文方法的有效性和准确性。

关键词: 振源识别; 场地微振动; 归一化梅尔滤波系数; K-medoids 聚类; 混合高斯模型

中图分类号: TN911.6 TH86 **文献标识码:** A **国家标准学科分类代码:** 510.40

Identification method of site micro-vibration source based on K-medoids clustering

Zhang Junyi, Yu Caizhi, Wang Peng, Sun Changku

(State Key Laboratory of Precision Measuring Technology and Instruments, Tianjin University, Tianjin 300072, China)

Abstract: Almost precision laboratories and semiconductor production plants have vibration isolated design. But, there may be still some vibration out of limit around. It turns into micro-vibration interference source after passing through vibration isolated installation. To find the interference sources around the site, it is necessary to classify and identify the detected blind sources signals. Due to the characteristics of low frequency, low amplitude, and short duration of the transient micro-vibration signal, traditional vibration signal analysis methods have difficulty to handle this. Thus, an identification method of micro-vibration source based on K-medoids is proposed. The endpoint detection algorithm is used to cut off transient micro-vibration signals from long-term data after preprocessing. Then, the normalized Mel filter coefficient (EN-Fbank) feature is extracted and used to constitute feature matrix. In addition, the data are clustered by K-medoids with dynamic time wrapping (DTW) distance. Finally, Gaussian mixture models are created for clustered data to identify the inspection data of the suspected vibration source with model probability threshold to find serious interference sources. In the experiment with 24 h data, two types of vibration sources with the largest average amplitude and the highest frequency of occurrence are found, and the classification accuracy reaches 90.57% besides the identification rate reaches 96.8%, which proves the effectiveness and accuracy of the method.

Keywords: vibration identification; site micro-vibration; Mel frequency cepstrum coefficient; K-medoids; Gaussian mixed model

0 引言

根据我国 2015 年颁布的《电子工业防微振工程技术规范》^[1] (GB 51076—2015) 所述, 各类精密仪器及设备为保证能够正常运行都有不同的场地微振动容许值及其他振动条件限制。对于电子工业及实验室中的精密设备及仪器, 以长路径激光设备为例, 频域限值在 1~100 Hz 时场地容许振动速度在 3.00 $\mu\text{m/s}$ 以内, 时域限值则根据不同种类的光学仪器容许振动速度限制在 300~700 $\mu\text{m/s}$ 不等。随着我国精密制造业和电子半导体产业的不断发展, 改善半导体厂房及实验室等的隔振环境势在必行。在场地选址、布局规划和场地防微振设计时都要对周围存在的振源进行充分的考量, 因此需要对场地存在的振动干扰源进行识别和探查。长时间存在的干扰振源会成为如良品率降低、各类仪器误差^[2] 等问题的隐患。为找出干扰振源, 需从长期观测信号中提取瞬态微振动信号, 通过分类并对后续排查振源时测得的信号进行识别从而发现干扰源和进行及时的隔振处理。

实验室及厂房等在建设时多会进行隔振墙、框架架空和铺设华夫板等隔振设计^[3], 可以将绝大部分的外界振源进行隔离, 但一些能量较大或距离较近的振源及某些设备自身振动会经过隔振设施转变成幅值低、频率分布在低频段的微振动。同时连续的周期振动常因持续时间长而较易发现, 但场地内的潜在隐患往往是出现无规律、持续时间短的瞬态振动, 例如厂区库房的装卸货、大型车辆等许多瞬态振源, 一些能量较大的瞬态振动会经隔振设施后仍可对设备造成影响。振动识别问题上已有的大量研究方法, 诸如主成分分析^[4] (principal component analysis, PCA)、经验模态分解^[5-6] (empirical mode decomposition, EMD)、卷积神经网络^[7] 等都是对具有周期性的信号进行分析及分类, 并不能解决本文所面临的工程问题。本文的重点是场地周围存在的瞬态微振动振源识别, 此问题更类似于语音识别领域内的“音素”识别, 单个的瞬态冲击具有极短的持续时间以及微振动信号的低频性都导致传统振动学特征^[8-10] 不能适用; 且振源自身可变性与产生距离的差异会导致振动时长上略有不同, 传统振动分析方法中常采用的固定分析窗长在此也同样不适用; 在长期监测下分析出现的各振动信号均由何产生又属于一种盲信号识别问题, 因此语音识别领域的有监督机器学习方法并不适用。

在此本文提出一种基于 K-medoids 分类的场地微振动振源识别方法, 同时包括一种适用于微振动信号的归一化梅尔滤波系数 (energy normalization-filter bank, EN-FBank) 特征提取方式和一种通过互相关无向图和轮廓系数法的振源种类数确定方式。首先利用端点检

测算法提取出每个瞬态微振动信号; 对全体数据进行特征提取, 构建特征矩阵; 再根据动态时间归整 (dynamic time warping, DTW) 距离进行 K-medoids 聚类算法对信号进行分类; 最后通过混合高斯模型 (Gaussian mixture model, GMM) 对每簇结果进行建模, 通过模型概率密度判定后续输入的信号是否为已测得的某类振源。

1 周期微振动振源分析

1.1 场地微振动信号特性

根据《电子工业防微振工程技术规范》中所定义微振动信号为表 1 所示的限值振动。

表 1 微振动限值
Table 1 Micro vibration limit

微振动物理量	振动位移 / μm	振动速度 /($\mu\text{m/s}$)	振动加速度 /(m/s^2)
频域振动幅值	≤ 0.50	≤ 50	$\leq 2 \times 10^{-1}$
时域振动幅值	≤ 10	$\leq 1\ 000$	-

本项目已在多个半导体厂房进行过多次实地微振动测试, 大量的测试数据表明场地微振动信号可以大体分为周期振动和瞬态振动两类, 如图 1 所示。

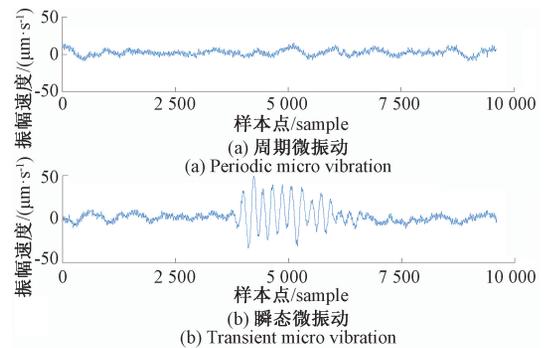


图 1 周期微振动与瞬态微振动

Fig. 1 Periodic micro vibration and transient micro vibration

1.2 周期振源分析

针对具有周期性的微振动信号, 可通过振幅平方相干结果进行判断存在何频率的周期振源。假设场地周围有传感器 \hat{X}_i 和 \hat{Y}_i , 分别布置在场地设备运作核心区域和场地外围或干扰振源附近, 并测得信号 \hat{x}_i 和 \hat{y}_i ; 根据 Welch 交叠分段平均法进行信号的功率谱估计即可得二者的功率谱密度估计 P_{xx} 和 P_{yy} 。同时计算 \hat{x}_i 和 \hat{y}_i 互功率

谱密度估计,如式(1)所示。

$$P_{xy}(\omega) = \sum_{m=-\infty}^{\infty} R_{xy}(m) e^{-j\omega m} \quad (1)$$

式中: $R_{xy}(m) = E\{x_n + my_n^*\} = E\{x_n y_{n-m}^*\}$ 。

对 \hat{x}_i 和 \hat{y}_i 进行如式(2)的振幅平方相干性计算并判断两传感器采集到的信号是否有相同的振源干扰,结果如图 2 所示。

$$C_{xy}(\omega) = \frac{|P_{xy}(\omega)|^2}{P_{xx}(\omega)P_{yy}(\omega)} \quad (2)$$

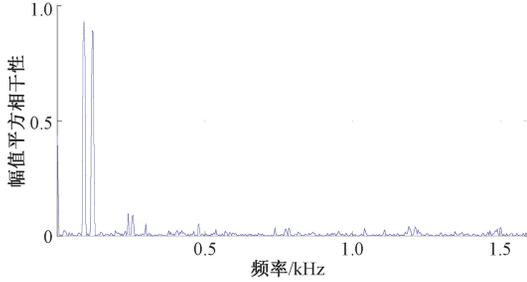


图 2 基于 Welch 的信号相干性

Fig. 2 Signal coherence based on Welch

从图 2 可知两示例信号中均存在 91 和 119 Hz 频率的振动,上述方法应用于判断场地核心区域是否受到场地边缘的周期振源干扰。

2 基于 K-medoids 分类的场地微振动振源识别方法

本文所针对的瞬态微振动信号具有幅值低、集中于低频段、持续时间短的特点,同时场地隔振设计可能导致同振源发出的振动在经过不同高度的隔振结构后在信号时长上略有区别,为此本文提出对于此类信号的特征提取方式和振源识别方法,完整框架如图 3 所示,具体步骤如下:

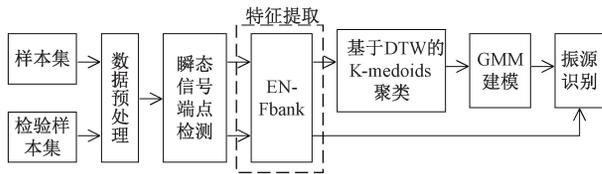


图 3 基于 K-medoids 分类的场地微振动振源识别方法框架

Fig. 3 Framework of the identification method of site micro-vibration source based on machine learning

1) 对样本集和检验样本集信号 $x(n)$ 进行谱减法降噪^[11]、分帧等预处理得到 $\hat{x}(n)$, 将去噪后的 $s(n)$ 进行端点检测算法,得到各瞬态微振动信号。

2) 对全体信号进行 EN-FBank 特征提取,得到特征矩阵 EF_i 。

3) 对样本集特征矩阵 EF_i 进行基于 DTW 距离的 K-medoids 聚类;根据互相关无向图和轮廓系数法确定场地所具有的振源种类数 K 。

4) 对分类后的样本集特征矩阵进行 GMM 建模,对检验样本集的特征矩阵进行概率密度检验,统计各检验样本对于不同模型的得分情况,确定所属类别。

2.1 端点检测算法

本文采用文献[12]基于统计模型的端点检测算法提取瞬态微振动信号,该方法假设目标信号(本文中为要截取的瞬态微振动信号)和无用信号(指没有瞬态微振动出现的区间,下文以“静默状态”代指)是独立的高斯分布,将已有目标信号和静默状态信号数据集分帧并做离散傅里叶变换(discrete Fourier transform, DFT),以每个子频带的能量为特征,利用二维高斯模型去拟合其分布,二维高斯模型的参数(权重 ϕ_i 、均值 μ_i 、方差 σ_i)由期望最大化算法^[13](expectation-maximization, EM)确定;最后由似然比结果确定每帧数据内存在目标信号的概率,主要过程如下:

1) 将 i 个训练数据集 $x_i(n)$ (分为瞬态微振动信号和静默状态两类)进行分帧,帧长和重叠度分别根据采样率和实际被测振动信号的时域长度设置为 $framesize$ 和 $overlap$; 并做短时傅里叶变换(short-time Fourier transform, STFT)得到每帧频域信号:

$$X_i(f) = \sum_{n=0}^{framesize-1} x_i(n) e^{-j2\pi fn} \quad (3)$$

2) 进行频带能量计算,设所用微振动传感器频率响应在 $F_{sensors}$ 左右,将 $[0, F_{sensors}]$ 划分为 N 个频率子带(通常取 6 个),为适应微振动信号的低频特性并增强两类信号的区分度,应对 1.2 节测得的周期频率以下及低频段粗划分为 1~2 个频段,而对其余频率范围进行细致划分。子频带能量计算公式:

$$P_j = \frac{1}{f_{j,up} - f_{j,low}} \sum_{k=f_{j,low}}^{f_{j,up}} |X(k)|^2 \quad (4)$$

式中: P_j 为第 j 个子带的能量, $f_{j,up}$ 与 $f_{j,low}$ 分别为子频带频率上下限, $X(k)$ 为转换后的频域信号。

3) 得到每个训练数据的能量特征矩阵 $Y_{i,m \times n}$; 其内各元素代表 $x_i(n)$ 的第 m 帧数据的第 n 个子带能量。

4) 使用式(5)简化的二维高斯分布去拟合子带能量分布,参数由 EM 算法迭代计算得到:

$$p(\mathbf{x}, \mathbf{y}) = \phi_1 \phi_2 \exp\left(-\frac{(\mathbf{x} - \boldsymbol{\mu}_1)^2}{\boldsymbol{\sigma}_1^2}\right) \exp\left(-\frac{(\mathbf{y} - \boldsymbol{\mu}_2)^2}{\boldsymbol{\sigma}_2^2}\right) \approx \phi_1 \exp\left(-\frac{(\mathbf{x} - \boldsymbol{\mu}_1)^2}{\boldsymbol{\sigma}_1^2}\right) + \phi_2 \exp\left(-\frac{(\mathbf{y} - \boldsymbol{\mu}_2)^2}{\boldsymbol{\sigma}_2^2}\right) \quad (5)$$

5) 将 $\hat{x}(n)$ 中连续 5 帧内都小于整体均值的区间进

行置零,实验证明相较幅值更显著且连续性更好的语音信号,该处理更有利于区分瞬态微振动信号。

6)将待处理数据进行同样的能量特征提取,通过得到的模型使用如式(6)的子带似然比计算公式,得到每帧数据存在目标信号的概率:

$$L_j(x, i, j) = \log \left(\frac{P_s(x, i, j)}{P_n(x, i, j)} \right) \quad (6)$$

$$L(x, i) = \sum_{j=1}^N L_j(x, i, j)$$

式中: $P_s(x, i, j)$ 与 $P_n(x, i, j)$ 分别代表由二维高斯模型计算得到的待处理数据第 i 帧第 j 个特征变量从属于目标信号和静默状态的概率;而 $L_j(x, i, j)$ 代表该帧的第 j 个子带能量对数似然比,将 N 个子带对数似然比求和,得到该帧的总体似然比 $L(x, i)$ 。

2.2 EN-FBank 特征提取

瞬态微振动信号通过大量实地测试发现持续时间通常在 0.5 s 左右,并且集中于低频段,振动速度从几十到几百 $\mu\text{m/s}$ 不等,相对跨度较大;如希尔伯特谱^[14]、小波分解和频带分析^[15]等传统特征并不适用,对本文目标信号区分度小,且无法有效辨识同种振源因自身或距离而导致同类信号间幅度不同的情况。特征提取对于后续学习分类任务极为重要,不同信号间特征的区分度直接影响分类的准确率;良好的特征提取方法应使同类数据之间的差距尽可能小,而不同类数据间的差距尽可能大。本文在此提出一种针对瞬态微振动信号的特征提取方法,通过改进 FBank^[16]特征中梅尔刻度比例和增加一种前馈机制的能量归一化方法来使其可以应用于本文信号的特征提取任务,步骤如下:

1)预加重滤波,通过一个高通滤波器,来增强语音信号中的高频部分,使频谱变得相对平坦,突出高频共振峰: $y(t) = x(t) - \mu x(t - 1)$, $\mu \in [0.9, 1)$ 。

2)分帧,将端点检测算法截取的瞬态微振动信号进行如前文设置的帧长、重叠率等分帧处理。

3)加窗,通常选用汉明窗来削弱频谱泄漏带来的误差。

4)短时傅里叶变换,对每一帧内的 N 点数据进行 FFT。

5)梅尔滤波器组滤波。

6)归一化处理。

由于微振动信号的低频特性,上述步骤 5)中梅尔频率刻度如式(7)所示,原始梅尔频率 $a = 700$, $b = 2595$,是一种符合人耳敏感度的频域非线性频率刻度,但根据工程经验瞬态微振动信号主要集中于 2 kHz 以下,原始的 a, b 值会导致信号整体频域特征区分度不明显,进而影响后续信号分类识别的准确性。

$$m = \text{blg} \left(1 + \frac{f}{a} \right) \quad (7)$$

以 $a = 1000$, $b = 4000$ 为例,图 4 是所设计的符合本文目标信号特性的 30 个梅尔滤波器组,同时对各滤波器采取除以底边长度的办法进行归一化以削弱低频段通常能量较高且集中的特点,提高高频段能量占比,增加特征间区分度。

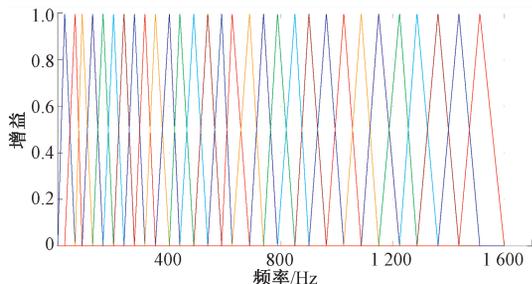


图4 $a=1000, b=4000$ 梅尔滤波器组

Fig. 4 Mel filter banks with $a=1000, b=4000$

一般在声学及语音等一维时域信号数据特征处理中都需要归一化来缩小同类型信号间的振幅差异,减小因测量距离不同、同个体幅度变化等问题的干扰;目前各类归一化方法繁多,本文采取 Wang 等^[17]在 2016 年提出的一种具有前馈机制的能量归一化方法作为减少幅值变化影响的手段,具体如式(8)和(9)所示。

$$\mathbf{EN}(t, f) = \left(\frac{\mathbf{E}(t, f)}{\varepsilon + \mathbf{M}(t, f)^\alpha} + \delta \right)^r - \delta^r \quad (8)$$

$$\mathbf{M}(t, f) = (1 - s)\mathbf{M}(t - 1, f) + s\mathbf{E}(t, f) \quad (9)$$

式中: $\mathbf{EN}(t, f)$ 是归一化后的特征向量, $\mathbf{E}(t, f)$ 是原始的 FBank 特征, ε 是一个防止除数为 0 的极小值,一般取 $\varepsilon = 10^{-6}$, 归一化强度由 α 控制且 $\alpha \in [0, 1]$;通常情况下参数的选取需要依据工程实际进行配置,在此给出一组符合本文目标信号特性且对后文的聚类算法有较好效果的参数设置: $s = 0.025$, $\alpha = 0.98$, $\delta = 2$, $r = 0.5$ 。

为直观展示本文所采取的信号特征和归一化方法,现以一样本瞬态微振动信号图 5(a) 为例,提取其由上述滤波器组过滤后的特征值,并通过绘制三维曲面图展示其未经归一化处理的 FBank 特征和经过上述归一化方法处理后的 EN-FBank 特征。通过观察和比对比图 5(b) 和 (c) 所示的三维曲面图,可以清晰地看到时域内的波形在频域上很好地反应了其特征变化,并且本文所采用的归一化方法不但从整体上降低了特征的幅度变化范围,同时也将低频区过多的无用信息滤掉,极大地提升了有用信息的占比。

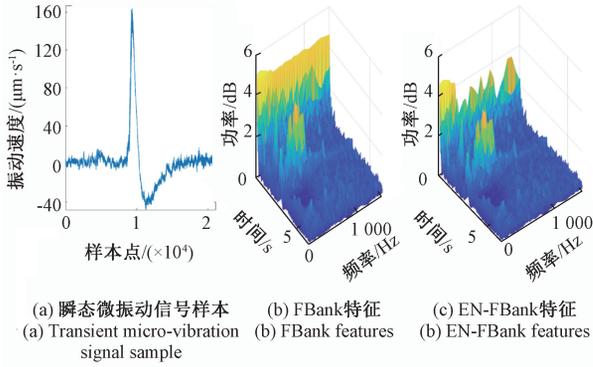


图 5 样本信号及其特征可视化

Fig. 5 Sample signal and feature visualization

将上述特征以数学形式表达为式 (10)。

$$\mathbf{EF}_i = \begin{pmatrix} \mathbf{EF}_i(1, f_1) & \cdots & \mathbf{EF}_i(1, f_j) \\ \vdots & \ddots & \vdots \\ \mathbf{EF}_i(t, f_1) & \cdots & \mathbf{EF}_i(t, f_j) \end{pmatrix}_{T \times J} \quad (10)$$

式中: \mathbf{EF}_i 是第 i 个信号提取出的特征矩阵, 行向量为该信号某帧数据的滤波器组特征值, 而每一列代表信号以帧长为跨度的时间范围。

2.3 基于 DTW 距离的 K-medoids 算法聚类

动态时间归整^[18]距离是量化两个时间序列相似度的一种重要手段, 是解决同类型信号因某些原因导致在发生顺序不变时总体时长不同的问题的有效手段, 广泛应用于语音识别、金融数据分析、生物特征信号分析等领域, 该算法是通过动态规划逐帧计算信号帧间欧几里得距离, 寻找能匹配两个信号的最小距离。

设有时域信号 $x(n)$ 、 $y(n)$, 且二者分别有特征矩阵 $\mathbf{X} = [\alpha_1, \alpha_2, \dots, \alpha_M]$ 和 $\mathbf{Y} = [\beta_1, \beta_2, \dots, \beta_N]$, 其中 α_i, β_i 为同帧长的、同纬度的特征向量, 将二者帧号分别作为横纵坐标组成一张二维网格, 网格内为对应帧间欧式距离, 找到一条累计距离 d 最小的路径:

$$d(\mathbf{X}, \mathbf{Y}) = \sum_{\substack{m \in [1, M] \\ n \in [1, N]}} \text{dist}_{mn}(\mathbf{X}, \mathbf{Y}) \quad (11)$$

两相似信号的时域特征出现顺序是固定的, 所以只能从网格左下到右上遍历, 而遍历规则只能为:

- 1) 垂直移动: $(m, n) \rightarrow (m + 1, n)$;
- 2) 水平移动: $(m, n) \rightarrow (m, n + 1)$;
- 3) 对角线移动: $(m, n) \rightarrow (m + 1, n + 1)$ 。

同时理想的规划路径应接近对角线, 固需要设置路径翘曲度确保算法不会导致过度拟合, 最终将最小欧式距离作为两信号间的 DTW 距离返回。

K-medoids 聚类算法是一种经典无监督机器学习算法, 旨在将批量数据找到 K 个中心点 (通常称为“质心”) 并根据质心分成 K 类, 是一种鲁棒性很好的分类算法, 算

法步骤分为如下 4 步:

1) 选取 k 个数据点作为质心, 随机选取一点作为第 1 个质心, 再选取到该点有最大 DTW 距离的点作为第 2 个质心, 第 3 个质心选择到前 2 个点 DTW 距离之和最大的点, 其余质心以此类推;

2) 按照与质心最近的原则, 将剩余点分配到当前具有最佳质心的类中;

3) 计算各类成员点对应的准则函数, 选取准则函数最小时对应的点作为新的质心, 在此选取该成员点到其他各点的 DTW 距离之和作为准则函数:

$$\text{Sumdist}_i = \sum_{j=1, j \neq i}^n d(\mathbf{X}_i, \mathbf{X}_j) \quad (12)$$

式中: Sumdist_i 为该类中某点 i 到同类内其他所有点的 DTW 距离之和;

4) 重复步骤 2)、3), 直到所有质心不再变化。

上文中数据点为微振动传感器采集到的各瞬态微振动信号特征矩阵, 同时识别被测场地存在的各类干扰源属于盲源分类问题, 常用方法有独立成分分析^[19] (independent component analysis, ICA) 等进行信号分离, 但对瞬态信号准确性差; 本文为对最优分类数 K 进行估计, 即预估振源数目, 提出一种基于图论的适用于瞬态微振动信号的方法——互相关无向图法和轮廓系数法结合的最优 K 值估计法, 分为以下 3 步:

1) 轮廓系数法: 以 k 为变量, 取值范围 2 到 K_i, K_i 为轮廓系数收敛时的 k 值, 对全体截取到的 i 个瞬态微振动信号进行多次聚类, 记录各 k 值下的轮廓系数, 轮廓系数计算公式如式 (13) 所示。

$$c_{\text{sum}}(k) = \frac{1}{n} \sum_{i=0}^n c(i) = \frac{1}{n} \sum_{i=0}^n \frac{b(i) - a(i)}{\max(b(i), a(i))} \quad (13)$$

式中: $a(i)$ 、 $b(i)$ 分别表示第 i 个信号到所属质心的 DTW 距离和到次近的质心的 DTW 距离, $c_{\text{sum}}(k)$ 代表 k 类聚类后全部信号的平均轮廓系数, 该值趋近于 1 说明分类越合理, 趋近于 -1 则说明分类有误。提取 $c_{\text{sum}}(k)$ 的全部峰值, 记作 $K_c(j)$ 。

2) 互相关无向图法: 轮廓系数法通常作为限制过度细分的标准, 但其在实际情况下可能存在多极值, 为进一步确定最优分类数, 以互相关无向图法对类内是否应进一步细分进行确定。将某类内的瞬态微振动信号两两做互相关运算, 得到以互相关值为元素的上三角矩阵; 当大量存在超出全体一倍标准差范围的元素时, 可以认为存在多个分布中心, 将对角元素置零并由 Davies-Bouldin 评价准则^[20]求解全部矩阵元素的 L 个分布中心, 以最大中心值作为邻接矩阵的转换阈值把互相关矩阵转换为邻接矩阵。计算邻接矩阵的全部连通分量, 若某分量节点数占最多分量的 30% ~ 40% 以上, 则认为是分类不完全情况, L 作为最小可继续细分数; 将各类内可细分数记作 $k_c(i)$, $i = 1, \dots, K$, 以其均值 $\bar{k}_c(i)$ 作为 $K = k$ 时整体可细

分指标 $K_c(k)$, 具体计算步骤如下:

$$\mathbf{M} \Rightarrow \mathbf{M}'_{n \times n} \Rightarrow \mathbf{M}''_{n \times n} \Rightarrow k_c(i) \quad (14)$$

式中: \mathbf{M} 为互相关矩阵, \mathbf{M}' 为对角元素置 0 后的结果, \mathbf{M}'' 为转换后的邻接矩阵, $k_c(i)$ 为通过连通分量数计算得到的簇内可细分数。

3) 最优分类数 K 值由 $K_c(k)$ 与 $K_c(j)$ 确定, 该值代表分类结果具有轮廓系数极大值且类内不可再分:

$$K = \{k | K_c(k) \in K_s(j), K_c(k) \rightarrow 1\} \quad (15)$$

2.4 基于混合高斯模型建模及阈值判定

混合高斯模型^[21-22]是一种拟合性很好的概率模型, 通过多个高斯函数的线性加权来拟合任意形状分布的数据。对于输入的向量 \mathbf{y} 与由 C 个高斯模型构成的参数集为 θ 的 GMM 模型可以通俗表达为:

$$P(\mathbf{y} | \theta) = \sum_{c=1}^C P(\mathbf{y}, c | \theta) = \sum_{c=1}^C \pi_c P(\mathbf{y} | c, \theta) \quad (16)$$

$$\sum_{c=1}^C \pi_c = 1; c = 1, 2, \dots, C.$$

式中: $P(\mathbf{y} | \theta)$ 为输入量属于该 GMM 模型的概率, $P(\mathbf{y} | c, \theta)$ 为 GMM 模型的第 c 个高斯分量, GMM 的参数集 θ 由各分量的均值向量 μ_c 、协方差矩阵 Σ_c 及混合分量的权值 π_c 组成。对于 GMM 模型的第 c 个高斯分量通常采用 F 维单高斯分布, F 等于特征数:

$$P(\mathbf{y} | c, \theta) = \frac{1}{(2\pi)^{\frac{F}{2}} |\Sigma_c|^{\frac{1}{2}}} \exp\left\{-\frac{(\mathbf{y} - \mu_c)^T \Sigma_c^{-1} (\mathbf{y} - \mu_c)}{2}\right\} \quad (17)$$

式中: Σ_c 通常取对角矩阵, 且方差在计算时需要允许误差限为 0.1 以内, 否则会导致个别协方差分量过小引起后续期望最大化算法求解参数时产生奇异方程。

通过上述基于 DTW 距离的 K-medoids 聚类算法已经在长时间内测得的大量瞬态微振动信号合理地分为 K 类, 现对每类信号的特征矩阵以每帧特征向量为单位进行 GMM 建模, 各高斯分量参数组 $\lambda = \{\pi_c, \mu_c, \Sigma_c, c = 1, 2, \dots, C\}$ 由期望最大化算法迭代得到, 高斯分量数 C 由赤池信息准则^[23] (akaike information criterion, AIC) 确定, 选取当模型临近过拟合时的 C 值作为最优分量数。该准则旨在通过最小化 AIC 值来避免模型过拟合, 减少建模时不必要的运算量。

根据全部 GMM 模型可以进行基于概率密度函数的后续输入信号评分识别, 判决式如下:

$$n^* = \arg \max_{1 \leq n \leq N} P(\mathbf{y} | \theta_n) = \arg \max_{t=1}^T P(\mathbf{y}_t | \theta_n) \quad (18)$$

式中: n^* 为具有最高概率的振源类别, $P(\mathbf{y}_t | \theta_n)$ 为输入信号第 t 帧属于第 n 类 GMM 模型的概率。具有最高概率的 $P(\mathbf{y} | \theta_n)$ 需和阈值 k^* 比较, 当大于 k^* 时才认为确属

于集内某类已知振源, 而 k^* 可以通过工程经验或同一块被测场地大量实验选取等错误率 (equal error rate, EER) 阈值或最小检测代价阈值等。

3 场地微振动振源识别方法实验分析

3.1 场地微振动信号采集实验平台

为验证本文所提出基于 K-medoids 分类的场地微振动振源识别方法的性能, 本文使用项目中自主搭建的微振动实时在线检测系统 (如图 6 所示) 进行信号的采集, 使用美国 Wilcoxon 公司的 731A 型加速度计和自主开发的前端信号调理电路及嵌入式数据采集模块进行微振动信号的测量与采集, 最后数据由工控机进行存储及显示, 传感器经积分环节输出与加速度成比例的电压信号。



图 6 微振动实时在线检测系统

Fig. 6 Micro-vibration real time on-line detecting system

传感器主要参数: 灵敏度 10 V/g、精度 $\pm 10\%$ 、量程 0.5 g、频率响应 1 600 Hz 左右、温度范围 $-10^\circ\text{C} \sim +65^\circ\text{C}$; 采集模块的采样频率 FS 设置为 3 200 sps; 传感器在厂房素地测试需配合地钉深入地表进行测量, 在超净间等室内环境需置于平整地面。

3.2 场地微振动振源识别方法效果验证

为验证本文所提方法的相关性能, 现在隔振台上以人为振动模拟 3 类微振动振源的各 16 个样本, 其中还分为距传感器 5 和 10 m 两组来充分模拟实地测试时可能遇到的振源位置不固定的情况。将样本集进行预处理并提取特征矩阵, 图 9 展示每类振源抽样 2 个样本 (不同距离各一) 的 EN-FBank 特征。

对 48 个实验信号样本进行特征提取并得到特征矩阵 \mathbf{EF}_t , EN-FBank 特征提取时频率范围为 $[0, FS/2]$, 帧长 $framesize$ 和 $overlap$ 分别设置为 960 和 320, 时频域转换使用汉明窗, 滤波器组参数如上文所述。

为便于高维特征可视化, 在此引入 t 分布随机近邻嵌入法 (t-distributed stochastic neighbor embedding, t-SNE), 该方法根据高维点间相似度将其融入低维数据中, 后文将以 \mathbf{EF}_t 作为高维点并展示在三维空间中; 对实验数据进行

EN-FBank 特征提取、互相关无向图和轮廓系数的融合聚类簇数 K 值估计和基于 DTW 距离的 K-medoids 聚类,得到如图 7、8 及表 2 所示的结果。

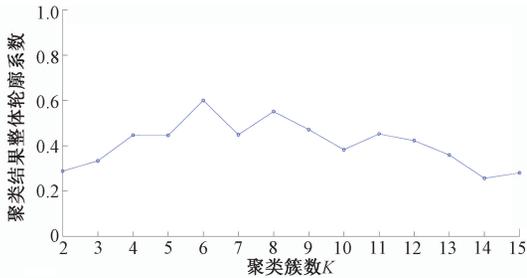


图 7 不同 K 值轮廓系数变化

Fig. 7 Variation of Silhouette coefficient with different K values

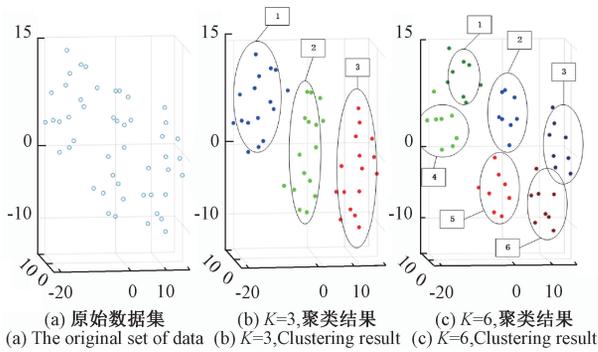


图 8 原始数据降维分布及 $K=3$ 、 $K=6$ 聚类结果

Fig. 8 Dimension reduction distribution of original data and clustering results of $K=3$ and $K=6$

表 2 类内互相关无向图连通分量数

Table 2 Number of connected components of each cross-correlation undirected graph within a cluster

聚类 K 值	$K=2$	$K=3$	$K=4$	$K=5$	$K=6$	$K=7$	$K=8$	$K=9$	$K=10$
平均连通分量	3.0	2.0	1.5	1.2	1.0	1.0	1.0	1.0	1.0

首先,根据图 9 所示的 3 类两种距离的振源特征图可以发现本文所设计的 EN-FBank 特征对于瞬态微振动信号有较好的适应性和鲁棒性,结合图 9(a) t-SNE 降维后可以看出该特征达到了类内特征间距小、类间间距大的特点,可以显著分为 3 类振源,且由于每类振源中又有被测距离的区别所以类间又显著分为距离振源 5 m 和 10 m 两类信号。其次,本文所提出的融合 K 值估计结果分别呈现在图 7 和表 2 中,图 7 展示了 $K=2\sim 15$ 的聚类结果整体轮廓系数,可以显著看出在 $K=6$ 和 $K=8$ 时有峰值;同时,对不同 K 值的类内数据进行互相关无向图分

析,将各类的连通分量均值记录在表 2,超过 10 类时内部更细致的分类无意义且已稳定于 1,所以表 2 仅展示 $K=2\sim 10$ 时整体的均值连通分量数,在 $K=6$ 时初次连通分量为 1,表示类内不可再分,证明最优 K 值为 6,这与 3 类振源两种测量距离的预期相符。

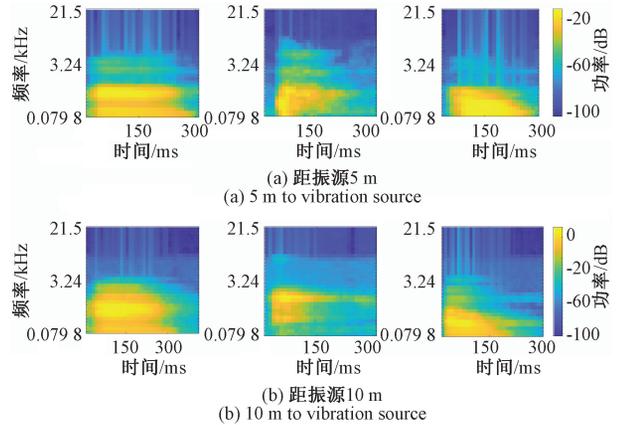


图 9 3 类实验微振动振源数据

Fig. 9 Three types of experimental micro-vibration source samples

根据最优 K 值进行本文提出基于 DTW 距离的 K-medoids 聚类算法,原始数据降维分布和 $K=3$ 、 $K=6$ 聚类后的结果如图 8 所示,证明了本文算法可以很好地适用于瞬态微振动信号的特性及其分类问题。

对 $K=3$ 、 $K=6$ 时的每类数据分别进行 GMM 建模,每类模型高斯分量数由 AIC 准则确定,通过 EM 算法得到各模型的参数组,并再测量每类振源两种距离样本各 3 个,共 18 个检验样本进行模型的概率密度计算同时进行阈值判定。其中在 $K=3$ 时,3 类振源可分别由 6、4、7 个高斯分量进行拟合,鉴别是否属于某类时的通过概率密度与不通过的概率密度结果平均相差 3 个量级,全部检验样本分类识别正确;在 $K=6$ 时,6 类振源可分别由 5~9 个高斯分量进行拟合,通过概率密度与不通过的概率密度结果平均相差 8 个量级,且平均是 $K=3$ 聚类后属于同类的概率密度结果的 50 倍左右,全部检验样本分类识别正确。上述结果体现了本文所提方法对于瞬态微振动信号具有极高的识别度,同时对于同振源发出的具有较明显距离差距的信号也有很高的识别率,并且在更大数据量时 GMM 模型鲁棒性将更高,分类结果更为准确。

3.3 24 h 实测场地微振动振源识别实验分析

通过本文项目所涉某北京半导体厂房素地的 24 h 实测场地微振动数据,来验证本文所提基于 K-medoids 分类的场地微振动振源识别方法的工程价值和实用性。对于场地所存在的周期振源利用上文所述方法提取其内包含的主要频率进而可寻找场地周围同频率的干扰源,

在此不进行额外叙述。将采集到的全天数据进行谱减法降噪、分帧等预处理后,进行关于瞬态微振动信号的端点检测算法,子频带划分为 $\{[0, 400], [400, 800], [800, 1\ 000], [1\ 000, 1\ 200], [1\ 200, 1\ 400], [1\ 400, 1\ 600]\}$,将每帧包含目标信号的概率绘制于图 10 中,由于数据量过大,以全天中前 2 h 的结果进行展示。为便于与时域数据进行比较,将所得似然比结果放大为 0~100 间整数。从图 10 中可以看出本文所提方法很好地判断出时域内全部的瞬态信号,后续可以进一步根据场地规定阈值滤去幅值较小的瞬态信号,仅截取超限的瞬态微振动信号,24 h 内共捕捉到 1 236 个瞬态微振动信号,长度集中在 1~3 个帧长内,最长 5 帧。

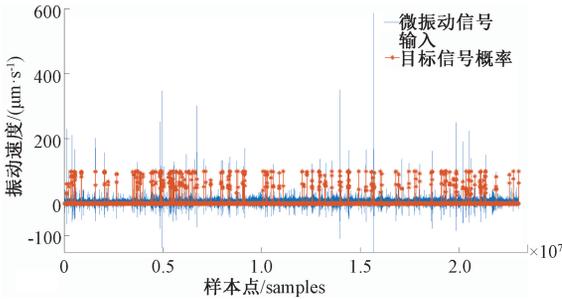


图 10 前两小时实测场地微振动信号及端点检测算法结果
Fig. 10 First two hours site micro vibration signal and target signal activity detection algorithm results

存储 24 h 内全部瞬态微振动信号并进行 EN-FBank 特征提取,并进行基于 DTW 距离的 K-medoids 聚类,通过轮廓系数法和互相关无向图法确定最优的聚类数目。结果如下图所示,通过图 11 可以看出不同 K 值分类方案的轮廓系数折线图在 2、14、17、20 时具有明显的峰值,并在 K=23 后开始出现收敛,与所测素地周围振动情况相符,被测地属于厂房规划建设用地并已被隔离,固振动情况较为安静,周围仅可能出现少量人为振动、库门开关、货品装卸等干扰振源,且幅值均属于微振动;将不同 K 值时分类结果平均类内连通分量数记录于表 3,当 $K \geq 20$ 后各分类结果各类内互相关值均在 1 倍标准差内,表明分类方案已足够细致;综上,最优分类数确定为 $K=20$ 。

表 3 24 h 数据类内互相关无向图连通分量数

Table 3 Connected components of each cross-correlation undirected graph of 24 h data within a cluster

聚类 K 值	K=2	K=5	K=10	K=14	K=17
平均连通分量	4.5	2.4	1.7	1.4	1.2
聚类 K 值	K=20	K=25	K=35	K=45	-
平均连通分量	1.0	1.0	1.0	1.0	-

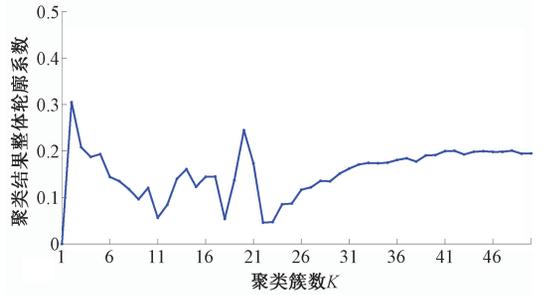


图 11 24 h 实测数据 $K=2\sim 50$ 分类结果轮廓系数
Fig. 11 Clustering results silhouette coefficient of 24 h data when $K=2\sim 50$

设在场地微振动条件不变的情况下,为提高 GMM 模型识别率与验证方法在足够数据量情况下的分类正确率,使用生成对抗网络^[24-26](generative adversarial networks, GAN)产生与原始样本分布相似的新样本,将扩充后 10 倍的样本分类结果展示于图 12,以不同颜色表征 20 类数据,可以看出本文提出的方法对被测场地出现的瞬态微振动信号实现了较好的分类效果。对各簇数据进行 GMM 建模,通过计算各簇数据内样本的 GMM 模型概率检验整体分类结果的正确率,分类正确率为 90.57%,证明了同类信号在概率上高度集中,信号相似度高,分类相对正确。通过对时域数据的统计找到平均幅值最大及出现频率最高的两类振源,初步分析是场地附近一库房门开关和周围人员走动所引起,分别采集 50 组数据构成检验样本集,并同样利用 GAN 网络产生同分布的新样本将检验集扩充至 5 000 个;进行特征提取及 GMM 模型识别分析;最终两种振源平均识别率为 96.8%。上述结果证明了本文所提特征及聚类方法对同振源发出的信号的分类准确度高,及对后续检验信号的有效识别。

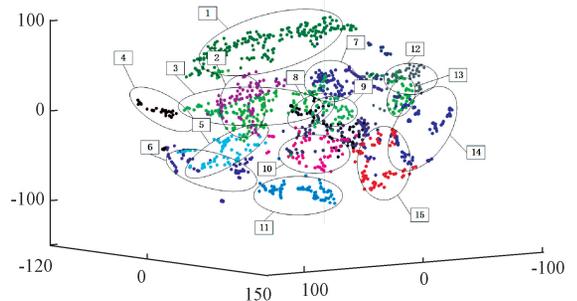


图 12 24 h 数据 $K=20$ 聚类三维结果
Fig. 12 Clustering 3D-results of 24 h data when $K=20$

4 结 论

本文针对半导体厂房瞬态微振动信号提出了适用的振源识别方法。周期振源根据主频率成分寻找干扰源,

而各类瞬态振源由端点检测算法从长时间监测中获取,通过 EN-FBank 特征提取后进行基于 DTW 距离的 K-medoids 聚类算法和 GMM 建模分类识别,通过理论研究和实验验证得到结论如下:

1) 本文提出的 EN-FBank 特征相较于传统时域信号特征参数,可以更好地适用于瞬态微振动信号,对目标信号进行了有效区分,以供后续算法准确分类。

2) 本文所提融合 K 值估计法很好地解决了微振盲源信号的分类数确定问题,基于 DTW 距离的 K-medoids 聚类算法与 GMM 识别方法对瞬态微振动信号的分类正确率达到 90.57% 并解决了同种振动信号持续时长不同的问题,成功找到场地周围幅值干扰最大及出现频率最多的两类振动干扰源,通过 GAN 网络生成干扰源的模拟信号进行识别检验,识别率达到 96.8%。

本文方法具有较好的工程实用性、准确性和鲁棒性,解决了场地周围微振动干扰源的识别问题。

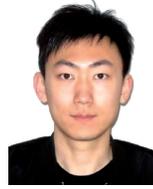
参考文献

- [1] 中华人民共和国工业和信息化部. 电子工业防微振工程技术规范:GB 51076—2015[S]. 北京:中国计划出版社,2014.
Ministry of Industry and Information Technology of the People's Republic of China. Technical principle for micro vibration prevention engineering of electronic industry: GB 51076-2015 [S]. Beijing: China Planning Press, 2014.
- [2] 郭路瑶. 一场关于地铁减振的博弈[J]. 城市轨道交通研究, 2018, 21(5):166.
GUO L Y. A game about subway vibration reduction[J]. Urban Mass Transit, 2018, 21(5):166.
- [3] 高广运, 聂春晓, 李绍毅. 电子厂房环境振动测试及有限元分析[J]. 合肥工业大学学报:自然科学版, 2016, 39(4):518-522.
GAO G Y, NIE CH X, LI SH Y. Environmental vibration measurement and finite element analysis of electronic workshop[J]. Journal of Hefei University of Technology: Natural Science Edition, 2016, 39(4):518-522.
- [4] ZHAO H M, ZHENG J J, XU J J, et al. Fault diagnosis method based on principal component analysis and broad learning system [J]. IEEE Access, 2019, 7: 99263-99272.
- [5] ZHAO H M, SUN M, DENG W, et al. A new feature extraction method based on EEMD and multi-scale fuzzy entropy for motor bearing[J]. Entropy, 2017, 19(1): 14.
- [6] 李帅永, 毛维培, 程振华, 等. 基于 VMD 和 K-SVD 字典学习的供水管道泄漏振动信号压缩感知方法[J]. 仪器仪表学报, 2020, 41(3):49-60.
LI SH Y, MAO W P, CHENG ZH H, et al. Compressed sensing method for leakage vibration signal in water-supply pipelines based on VMD and K-SVD dictionary learning[J]. Chinese Journal of Scientific Instrument, 2020, 41(3):49-60.
- [7] 武智超, 王慧, 王吉亮, 等. 基于阵列漏磁信号分析的无刷直流电机高阻接触故障诊断研究[J]. 电子测量与仪器学报, 2021, 35(11):108-114.
WU ZH CH, WANG H, WANG J L, et al. Fault diagnosis of high resistance connection in brushless DC motor based on analysis of array leakage flux signals[J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(11):108-114.
- [8] 田旭, 马晓川, 封超, 等. 基于稀疏分量分析的振动信号源识别方法[J]. 信号处理, 2021, 37(6):1034-1045.
TIAN X, MA X CH, FENG CH, et al. Vibration signal source identification method based on sparse component analysis[J]. Journal of Signal Processing, 2021, 37(6): 1034-1045.
- [9] YANG L, WANG Y S, WEI L. A novel identification method for micro-vibration analysis of reaction wheel assembly[J]. Acta Astronautica, 2022, 196:94-106.
- [10] DENG W, ZHANG SH J, ZHAO H M, et al. A novel fault diagnosis method based on integrating empirical wavelet transform and fuzzy entropy for motor bearing[J]. IEEE Access, 2018, 6: 35042-35056.
- [11] CHEN M, LEE C M. De-noising process in room impulse response with generalized spectral subtraction [J]. Applied Sciences, 2021, 11(15): 6858.
- [12] WU J, ZHANG X L. An efficient voice activity detection algorithm by combining statistical model and energy detection[J]. Eurasip Journal on Advances in Signal Processing, 2011, 2011(1):1-10.
- [13] AN P, WANG ZH Y, ZHANG CH J. Ensemble unsupervised autoencoders and Gaussian mixture model for cyberattack detection[J]. Information Processing & Management, 2022, 59(2), 102844.
- [14] 祝文颖, 冯志鹏. 基于迭代 Hilbert 变换的行星齿轮箱振动信号分析[J]. 浙江大学学报:工学版, 2017, 51(8):1587-1595.
ZHU W Y, FENG ZH P. Analysis of planetary gear vibration signal based on iterated Hilbert transform[J]. Journal of Zhejiang University: Engineering Science, 2017, 51(8):1587-1595.
- [15] GLOWACZ A, GLOWACZ W, GLOWACZ Z, et al. Early fault diagnosis of bearing and stator faults of the single-phase induction motor using acoustic signals[J]. Measurement, 2018, 113:1-9.

- [16] 李云红, 梁思程, 贾凯莉, 等. 一种改进的 DNN-HMM 的语音识别方法 [J]. 应用声学, 2019, 38(3): 371-377.
LI Y H, LIANG S CH, JIA K L, et al. An improved speech recognition method based on DNN-HMM model [J]. Journal of Applied Acoustics, 2019, 38(3): 371-377.
- [17] WANG Y, GETREUER P, HUGHES T, et al. Trainable frontend for robust and far-field keyword spotting [J]. 2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 2017: 5670-5674.
- [18] CHOI W, CHO J, LEE S, et al. Fast constrained dynamic time warping for similarity measure of time series data [J]. IEEE Access, 2020, 8, 222841-222858.
- [19] SHI L J, WANG Y K, LIAO M F, et al. Approach and application of semi-blind source separation for aero-engine vibration signals using ICA-R [J]. Journal of Physics: Conference Series, 2019, 1215: 012030.
- [20] SINGH A K, MITTAL S, MALHOTRA P, et al. Clustering evaluation by davies-bouldin index (DBI) in cereal data using K-means [C]. 2020 Fourth International Conference on Computing Methodologies and Communication (ICCMC), 2020: 306-310.
- [21] MALIUK A S, PROSVIRIN A E, AHMAD Z, et al. Novel bearing fault diagnosis using gaussian mixture model-based fault band selection [J]. Sensors, 2021, 21(19): 6579.
- [22] 曹丰. 基于 CNN 和 GMM 的旋转机械故障诊断方法 [D]. 哈尔滨: 哈尔滨理工大学, 2021.
CAO F. Fault diagnosis method of rotating machinery based on CNN and GMM [D]. Harbin: Harbin University of Science and Technology, 2021.
- [23] CAVANAUGH J E, NEATH A A. The akaike information criterion: Background, derivation, properties, application, interpretation, and refinements [J]. Wiley Interdisciplinary Reviews: Computational Stats, 2019, 11(3): e1460.
- [24] WANG Z R, WANG J, WANG Y R. An intelligent diagnosis scheme based on generative adversarial learning deep neural networks and its application to planetary gearbox fault pattern recognition [J]. Neurocomputing, 2018, 310(OCT. 8): 213-222.
- [25] MA L, DING Y, WANG Z L, et al. An interpretable data augmentation scheme for machine fault diagnosis based on a sparsity-constrained generative adversarial network [J]. Expert Systems with Applications, 2021, 182, 115234.

- [26] FU Q, WANG H W. A novel deep learning system with data augmentation for machine fault diagnosis from vibration signals [J]. Applied Sciences-Basel, 2020, 10(17): 5765.

作者简介



张钧奕, 2019 年于合肥工业大学获得学士学位, 现为天津大学硕士研究生, 主要研究方向为微振精密测试技术。

E-mail: 18822112832@139.com

Zhang Junyi received his B. Sc. degree from Hefei University of Technology in 2019.

He is currently a M. Sc. candidate at Tianjin University. His main research interests include micro-vibration precision measurement technology.



余才志, 1997 年于辽宁工程技术大学获得学士学位, 2016 年于天津大学获得硕士学位, 现为天津大学博士研究生, 主要研究方向为微振精密测试技术。

E-mail: yucz@edri.cn

Yu Caizhi received his B. Sc. degree from Liaoning Technical University in 1997 and M. Sc. degree from Tianjin University in 2016. He is currently a Ph. D. candidate at Tianjin University. His main research interests include micro-vibration precision measurement technology.



王鹏 (通信作者), 分别于 2004 年、2008 年在天津大学获得学士学位和博士学位, 现为天津大学教授, 主要研究方向为激光及光电测试技术、三维数字化测量技术等。

E-mail: wang_peng@tju.edu.cn

Wang Peng (Corresponding author) received his B. Sc. degree and Ph. D. degree from Tianjin University in 2004 and 2008. He is currently a professor at Tianjin University. His main research interests include laser and photoelectric testing technology, three dimensional digital measurement technology.



孙长库, 1989 年于哈尔滨工业大学获得学士学位, 1994 年于俄罗斯圣彼得堡精密机械与光学学院获得博士学位, 现为天津大学教授, 主要研究方向为激光及光电测试技术、三维数字化测量技术、微振精密测试技术等。

E-mail: sunck@tju.edu.cn

Sun Changku received his B. Sc. degree from Harbin Institute of Technology in 1989 and Ph. D. degree from St. Petersburg State University of IT, Mechanics and Optics in 1994. He is currently a professor at Tianjin University. His main research interests include laser and photoelectric testing technology, three dimensional digital measurement technology, and micro-vibration precision measurement technology.