◇ 研究报告 ◇

# 应用深度学习识别法兰螺栓连接状态

# 张 洪† 刘彬彬

(江南大学机械工程学院 无锡 214122)

**摘要**:针对常规诊断方法对螺栓的连接状态识别效果差、鲁棒性和抗噪性弱等问题,提出了基于深度学习理论的螺栓检测新方法。首先以4种预紧力状态下的法兰螺栓结构产生的声发射信号为研究对象,借助于自适应 噪声的完整集成经验模态分解理论以及梅尔频率倒谱系数特征提取方式,实现了声发射信号的自适应消噪和 最优模态函数分量组的选取,提取到了可以较好分辨螺栓连接状态的梅尔频率倒谱系数特征值。通过训练模型,较好地对4种连接状态下的螺栓进行了识别。结果表明,该模型在法兰螺栓的声发射信号的诊断中,准确 率高,具有较好的抗噪性和鲁棒性。

关键词:法兰螺栓;声发射;梅尔频率倒谱系数;深度学习;状态识别

中图法分类号: TP391.4; TB52+9 文献标识码: A 文章编号: 1000-310X(2021)03-0350-08 DOI: 10.11684/j.issn.1000-310X.2021.03.005

#### The recognition of flange bolt connection state based on deep learning

ZHANG Hong LIU Binbin

(School of Mechanical Engineering, Jiangnan University, Wuxi 214122, China)

Abstract: Aiming at the problems of conventional diagnostic methods in identifying the connection state of bolts, weak robustness and noise resistance, a new method of bolt detection based on deep learning theory is proposed. Firstly, the acoustic emission signals generated by the flange bolt structure under four kinds of preloading force are taken as the research object, relying on the complete ensemble empirical mode decomposition with adaptive noise (CEEMDAN), and the feature extraction method of Mel-frequency cepstral coefficients (MFCC). The adaptive noise reduction of the acoustic emission signal and the selection of the optimal basic mode component group are realized. The eigenvalues of Mel-frequency cepstral coefficients that can better distinguish the bolt connection state are extracted. Through the training model, the bolts in the four connection states are well identified. The results show that the model has high accuracy in acoustic emission diagnosis of flange bolts, and has good noise resistance and robustness.

**Keywords:** Flange bolt; Acoustic emission; Mel-frequency cepstral coefficients; Deep learning; State recognition

2020-07-15 收稿; 2020-12-03 定稿

†通信作者 E-mail: 1105399774@qq.com

作者简介:张洪(1966-),男,江苏无锡人,博士,副教授,研究方向:信号与信息处理,机电检测与控制技术。

# 0 引言

螺栓是法兰连接装置常用的部件,螺栓松动具 有很大的安全隐患[1],会导致法兰密封的失效,造 成泄漏事故,因此对法兰螺栓连接机构进行检测具 有重要的意义。声发射 (Acoustic emission, AE) 是 材料内部因能量的快速释放而产生瞬态弹性波的 一种常见物理现象,声发射技术是指利用仪器探测 并接收材料声发射信号而实现材料的动态非破坏 性检测的一种技术<sup>[2]</sup>。现有研究表明,螺栓轻微的 碰擦就能产生比较明显的声发射现象,借助声发射 技术可以有效地对螺栓连接状态进行识别<sup>[3]</sup>。传统 的声发射信号解释方法主要是时域、频域和参数分 析,提取声发射信号的特征值如幅值、均方根(Root mean square, RMS) 值、能量、振铃计数和时频域 特征等[4-7],将提取的特征值输入到支持向量机或 BP神经网络等机器学习模型进行训练<sup>[8]</sup>,然后将 训练好的模型用于识别。这种识别方式易受环境影 响,鲁棒性能和抗噪性能较差,而采用深度学习的 方法可以改善这些缺点。深度学习最典型的模型就 是卷积神经网络(Convolutional neural networks, CNN), CNN 在语声和图像分类任务中被广泛的应 用,近些年来也常用于机械设备故障诊断<sup>[9]</sup>。CNN 可以通过卷积的方式从数据中提取复杂并且具有 鲁棒性的多维度特征,使得模型有着更高的精度和 鲁棒性<sup>[10]</sup>。文献[11-13]采用CNN模型实现了螺栓 连接状态的辨别,但是他们所用方法只适用于完全 松动的螺栓,不能辨别螺栓的过紧或过松状态。将 深度学习与声发射技术结合起来可以很好地解决 上述问题,但是用原始时域信号作为输入样本,一是 存在噪声干扰问题,二是存在模型过拟合问题,需要 将输入样本进行适当的处理以提高信号的辨识度。

因此,本文提出了一种基于自适应噪声的完 整集成经验模态分解理论 (Complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN)、梅尔频率倒谱系数 (Mel-frequency cepstral coefficients, MFCC) 以及 CNN 的螺栓连 接状态诊断模型 (CEEMDAN-MFCC-CNN)。首先 通过 CEEMDAN 分解来获取声发射信号的固有模 态函数分量 (Intrinsic mode function, IMF),其次 借助峭度 (K)和互相关系数 (R)选取最优的 IMF 分量,然后自动提取所选 IMF 分量的 MFCC 系数, 实现对输入样本的处理,最后将样本数据输入到卷 积神经网络进行训练。试验结果表明,采用本文所 用方法可以很好辨别螺栓预紧状态,且具有较好的 抗噪性和鲁棒性。

#### 1 基本理论

#### 1.1 最优 IMF 分量组选取

对于需要选取的多个IMF分量,选择的分量不 仅要尽可能包含原始信号的关键信息,也要包含较 少的噪声。在最优 IMF 分量组的选取上,本文采用 CEEMDAN 对原始AE 信号分解<sup>[14]</sup>,并采用峭度 (K)、互相关系数(R)两者结合作为最优分量组选 取标准。峭度 K 是反映随机变量分布特性的数值 统计量,在信号中它反映的是信号中的冲击成分, 峭度值越大则信号中的冲击成分越多,也就是包含 着更多的故障特征。互相关系数代表了被分解信 号的IMF分量与其本身之间的相关程度,系数值越 大则表示IMF 分量和被分解信号之间越相似。本 文将峭度系数进行归一化处理后,设定择优系数  $\eta = K + R$ 作为选取指标,根据重构信号的均方误 差(Mean square error, MSE) 值作为评价的指标, MSE 值反映了噪声能量大小,其值越小越好<sup>[15]</sup>。通 过择优系数对 IMF 分量进行筛选, 不仅可以得到含 有故障信息较多的IMF分量,还可以剔除干扰成分 较多的虚假IMF 分量,选取过程如下所示:

(1)首先将标准正态分布的白噪声 $\lambda^{i}(t)$ 添加 到原始信号s(t)中, 第i次的信号可以表示为  $s^{i}(t) = s(t) + \lambda^{i}(t)$ ,其中添加次数 $i = 1, 2, 3, \cdots, k$ , 对 $s^{i}(t)$ 进行第一次经验模态分解(Empirical mode decomposition, EMD)分解得到IMF $_{1}^{i}$ ,那么添加k次所得到的IMF<sub>1</sub>和残差 $\delta_{1}(t)$ 为

$$IMF_1 = \frac{1}{k} \sum_{i=1}^{k} IMF_1^i, \qquad (1)$$

$$\delta_1(t) = s(t) - \mathrm{IMF}_1. \tag{2}$$

(2) 然后求 IMF 二阶分量 IMF<sub>2</sub>,将求得的残差  $\delta_1(t)$  添加白噪声  $\lambda^i(t)$ ,进行 EMD 分解得到二阶分 量 IMF<sub>2</sub> 和残差  $\delta_2(t)$ ,则

$$IMF_2 = \frac{1}{k} \sum_{i=1}^k IMF_2^i, \qquad (3)$$

$$\delta_2(t) = s(t) - \text{IMF}_2. \tag{4}$$

# 应用声学



Fig. 1 IMF component selection process

(3)重复以上过程,直到分解之后残差满足单调 而且无法进行分解计算结束,信号可以表示为

$$s(t) = \sum_{i=1}^{n} \text{IMF}_{i} + \delta_{n}(t).$$
(5)

(4) 取上述得到的 IMF 分量, 计算各个 IMF 分量的峭度值 K和互相关系数 R, 设置 K和 R 的初始 值为 0.05, 选取系数大于初始值的分量重构成新信 号,并计算新信号的 MSE 值。通过对 K和 R 值的不 断更新以及信号的重构, 最终挑选出 MSE 值最小时 的 IMF 分量组, 该算法选取流程如图 1 所示。

#### 1.2 Mel频率倒谱系数提取

人耳对不同频率的语声具有不同的感知能力, Mel频率正是为了描述这种感知特性而提出的,它 与频率呈非线性关系。Mel倒谱系数(MFCC)是根 据 Mel频率和系统固有频率对应关系,提取的一种倒 谱系数,MFCC经常应用于语声特征提取。所处理信 号的物理频率和 Mel 频率之间满足以下关系<sup>[16]</sup>:

 $Mel(f) = 2595 \times \lg(1 + f/700).$ (6)

声发射信号也可以采用此类方法来提取相应的特征,得到最优IMF分量组后,采用以下步骤提取方法提取IMF分量的MFCC系数,提取流程如图2所示。

(1) 对信号进行预处理(分帧、加窗、加重),加窗 时使用 hamming 窗。

(2) 对预处理之后的分帧信号进行离散傅里叶 变换 (Discrete Fourier transform, DFT), 预处理之 后时域信号为s(n), 设定 DFT 的点数为N, 经 DFT 变换之后得到频域信号 $S_k$ :

$$S(k) = \sum_{n=0}^{N-1} s(n) e^{-j2\pi nk/N},$$
  
$$0 \leq n, \quad 0 \leq k \leq N-1.$$
(7)

(3) 将 S<sub>k</sub> 开平方, 求得其能量谱, 用 J 个 Mel 滤 波器进行滤波处理, 那么第 j 次滤波的传递函数为

$$H_{j}(k) = \begin{cases} 0, & k < f(j-1), \\ \frac{2(k-f(j-1))}{(f(j+1)-f(j-1))(f(j)-f(j-1))}, \\ f(j-1) \leq k \leq f(j), \\ \frac{2(f(j+1)-k)}{(f(j+1)-f(j-1))(f(j+1)-f(j))}, \\ f(j) \leq k \leq f(j+1), \\ 0, & k > f(j+1). \end{cases}$$
(8)

计算每一个滤波器的对数能量,第J个滤波器 数组的对数能量为

$$S(j) = \ln\left(\sum_{k=0}^{N-1} |S(k)|^2 H_j(k)\right), 0 \le j \le J.$$
(9)

再经离散余弦变换得到 Mel 倒谱系数:

$$C(n) = \sum_{j=0}^{J-1} S(j) \cos(\pi n(j+0.5)/J),$$
  

$$0 \le j \le J.$$
(10)

J就是Mel滤波器的数量,也就是MFCC特征 值的维数,在这里选择J = 13。







#### 1.3 所用诊断模型

CNN的参数具有局部连接、参数共享的特点, 能有效避免梯度问题<sup>[17]</sup>。常用的卷积神经网络有 3种,分别为一维、二维和三维卷积神经网络,它们 都由卷积层、激活层、池化层和全连接层构成。一 维卷积神经网络(1D-CNN)本质上和二维卷积神经 网络(2D-CNN)相同,1D-CNN只适用于一维序列, 虽然1D-CNN只有1个维度,但是也具备CNN特征 识别平移不变性的优点<sup>[18]</sup>。在结构上,1D-CNN 与 2D-CNN相似,主要包括卷积层和池化层,也是通过 全连接层输出分类的结果,不同的地方体现在卷积 层和池化层的计算结构方面。本文采取1D-CNN作 为诊断模型,采用3个卷积池化层的结构,通过全连 接层输出分类的结果,本文所设计模型结构如图3 所示。

#### 2 试验与分析

#### 2.1 试验数据采集

法兰螺栓连接结构的声发射检测试验在振动 试验台上进行,试验现场如图4所示。



试验所用模拟法兰盘由上下两部分组成,试件下部通过螺栓紧固在振动台上,保证振动环境下和振动台绝对静止。试件上下部通过直径8 mm的两个螺栓连接,所有接触面放置橡胶垫,防止接触面产生干扰AE信号,在试件顶端对称放置两个声发射传感器。传感器为SR150M系列谐振式传感器,频率范围为60~400 kHz。设置采样频率为





(a) 振动试验台



(b)数据采集仪器图 4 试验现场Fig. 4 Test site

1000 kHz,采样点数为2048,波形和参数门限为 38 dB。通过扭力扳手控制螺栓预紧力的大小,分别 设置力矩为20 N·m、10 N·m、5 N·m、0 N·m,对应螺 栓连接的4种状态,如图5所示。

通过试验发现,当机构较长时间处于振动环境 下,螺栓的预紧力会慢慢减小,振动频率越快,预 紧力减小的速度越快,为了消除影响,本文在数据 采集和诊断模型方面进行了优化处理。首先本文 每种信号采样时间为10 s,采样结束后重新预紧螺 栓进行采集,避免了数据采集时预紧力的变化。其 次是在诊断模型中引入了正则化处理方式,在诊 断模型的全连接层进行了Dropout处理,随机丢弃 了一些参数来提高模型的鲁棒性和泛化性能,减少 了外界环境的改变对试验结果的影响。本文所用 振动台的振动频率为50 Hz,加速度为10 m/s<sup>2</sup>。将 法兰螺栓连接机构固定在振动台上,保持加速度 和振动频率不变,通过扭矩扳手分别设置螺栓预 紧力为 $L_1$  (20 N·m)、 $L_2$  (10 N·m)、 $L_3$  (5 N·m)和  $L_4$  (0 N·m),对应螺栓的过紧、正常、过松、失效状态。采集到的部分声发射时域信号如图6所示。

# 2.2 试验数据分析

单纯依靠AE时域信号难以判断信号中所包 含的关键信息,也就无法对螺栓的4种连接状态进 行判别。为了实现准确判别,在数据处理时采用 本文提出的最优IMF分量选取方法,然后对各信 号最优IMF分量进行MFCC系数提取,并借助核 主成分分析(Kernel principal component analysis, KPCA)方法,选取了贡献率较大的36个系数作为 各信号的特征值,部分样本的特征值如图7所示。



# 图6 不同扭矩下AE信号

Fig. 6 AE signal at different torques



图 7 MFCC 特征值图 Fig. 7 MFCC characteristic value

当螺栓预紧力变小时,由于没有预紧力的作 用,导致螺栓与螺母之间的运动变得更加自由,会 产生更多摩擦,导致AE信号增多,而当预紧力为0 时,螺栓连接结构失效,这时产生的AE信号是最 多的。分析图7可以看出,当螺栓处于过松(5 N·m) 和正常连接状态(10 N·m)时,MFCC系数最大值分 布在100左右,正常连接状态时的特征曲线较为平 坦,过松时变得陡峭。当预紧力继续变小而失效时 (0 N·m),MFCC系数增大到200左右,特征曲线更 加陡峭。而当螺栓处于过紧(20 N·m)状态时,特征 曲线的后半部分较为陡峭。无论是过紧、过松以及 失效,都和正常信号有着较大区别,采用MFCC系 数很好地评价了螺栓的连接状态。得到上述数据样 本后,将数据样本输入到诊断模型进行训练,数据样 本划分如表1所示。

表1 数据集样本 Table 1 Sample data set

| 样本集 (力矩)                           | 样本数量 | 训练集 | 测试集 | One hot 编码 |
|------------------------------------|------|-----|-----|------------|
| $L_1(20 \text{ N} \cdot \text{m})$ | 900  | 850 | 50  | 1000       |
| $L_2(10 \text{ N} \cdot \text{m})$ | 900  | 850 | 50  | 0100       |
| $L_3(5 \text{ N} \cdot \text{m})$  | 900  | 850 | 50  | 0010       |
| $L_4(0 \text{ N} \cdot \text{m})$  | 900  | 850 | 50  | 0001       |

## 2.3 试验结果分析

诊断模型运行的软件环境为PyCharm,硬件环境为Intel Core i5-8400处理器和GTX 1060显卡,取20次训练的平均值作为最终结果。经过训练,训练集和验证集的准确率均在97%左右,没有出现过拟合的现象,损失值和准确率结果如图8所示,测试集分类结果如图9所示。

表 2 对比结果 Table 2 Compare results

| 数据样本         | 训练模型    | 准确率/% |
|--------------|---------|-------|
| 原始时域信号       | CNN     | 77.50 |
| 原始信号 MFCC    | CNN     | 84.24 |
| 声发射相对当量能量    | CNN     | 90.62 |
|              | CNN     | 97.64 |
| CEEMDAN+MFCC | SVM     | 91.13 |
|              | BP 神经网络 | 92.36 |

通过图9看出,误判的部分主要出现在L<sub>3</sub>(过 松)和L<sub>4</sub>(失效)样本上,结合图7的MFCC特征值 图分析来看,大概率是由于L<sub>3</sub>和L<sub>4</sub>部分样本的特 征结构相似,造成了一定概率的误判,对于L<sub>1</sub>(过 紧)和L<sub>2</sub>(正常)样本,则实现了准确的判别。为了验 证该方法的有效性,选取了不同的数据样本和训练 模型等作为对比,试验结果如表2所示。



图8 训练的损失值和准确率





a max / Xax



通过对比分析,本文所用诊断模型很好地实现 了对螺栓AE信号的识别,准确率最高,达到了97% 左右,优于其他诊断模型。为了进一步的验证诊断 模型的泛化性能,本文通过改变螺栓预紧力和振动 台频率、加速度的大小,获得新的AE信号,然后对 新的AE信号进行识别,来探究振动台的频率和加 速度改变是否会对试验结果造成影响。验证试验取 10次测试的平均值作为最终结果,结果如表3所示。

表 3 验证信号识别结果 Table 3 Verify signal recognition results

| 振动<br>频率/Hz | 加速度/<br>(m·s <sup>-2</sup> ) | 预紧力矩/<br>(N·m) | 识别结果      |
|-------------|------------------------------|----------------|-----------|
| 55          | 15                           | 8              | 过松:98.36% |
| 45          | 10                           | 15             | 过紧:93.54% |
| 60          | 15                           | 12             | 过紧:91.25% |
| 55          | 10                           | 10             | 正常:99.98% |
| 40          | 15                           | 0              | 失效:99.99% |

改变振动台的频率和加速度之后,诊断模型依旧有着很高的准确率,说明在训练过程中,本文所用诊断模型消除了振动频率和振动加速度改变所带来的影响,很好地评价了螺栓连接状态,具有较高的泛化性能和鲁棒性。

## 2.4 抗噪性能分析

AE信号容易受机电噪声干扰,所以诊断模型 应具备抵抗噪声的能力,本文所用诊断模型不是对 原始AE信号进行识别,而是应用CEEMDAN分解 将原始AE信号分解为多个IMF分量,并通过设计 的寻优算法自动选择需要处理的IMF分量,用所选 分量的MFCC系数作为样本输入,这在一定程度上 增加了输入数据的随机性和降低了噪声的干扰。为 了验证诊断模型的抗噪效果,进行了抗噪试验,通过 在原有的AE信号上加入高斯白噪声,获得了不同 信噪比(Signal-to-noise ratio, SNR)的噪声信号,然 后将经过不同处理的噪声信号作为输入样本,探究 不同的处理方式对于试验结果的影响,结果如表4 所示。

在加入噪声之后,采用本文所用方法可以很好 地消除噪声的干扰,在识别准确率方面优于其他方 法,说明本文所用方法可以提取到更为有效的故障 信息,具有良好的抗噪性能。

#### 表4 含噪信号识别结果

Table 4 Noisy signal recognition result

| 含噪信号   | 信号处理方式        | 识别准确率/% |
|--------|---------------|---------|
|        | 无处理           | 67.5    |
| SNR:-1 | 提取原始时域信号 MFCC | 82.5    |
|        | 本文方法          | 92.5    |
| SNR:-2 | 无处理           | 62.5    |
|        | 提取原始时域信号 MFCC | 77.5    |
|        | 本文方法          | 90.0    |

## 3 结论

本文利用深度学习理论实现了法兰螺栓在 4种连接状态下的声发射信号的识别,构建的 CEEMDAN-MFCC-CNN诊断模型实现了声发射 信号的自适应消噪和特征自提取,具有较高的诊断 精度,有效地解决了抗噪性、鲁棒性差的问题。通过 与传统的方法进行对比,说明了基于深度学习理论 的信号识别方法的优越性。

#### 参考文献

- 史文博, 杜静, 龚国伟. 风电机组主轴法兰螺栓连接疲劳损伤 分析 [J]. 机械设计与制造, 2020(4): 226-229.
   Shi Wenbo, Du Jing, Gong Guowei. Fatigue damage analysis of bolts connection between mainshaft and flange on wind turbine[J]. Machinery Design and Manufacture, 2020(4): 226-229.
- [2] 唐玉玲,姜智,周振功,等.碳纤维增强环氧树脂复合材料螺 栓连接结构在拉伸载荷下损伤过程的声发射分析 [J].复合材 料学报,2019,36(8):1854–1863.
   Tang Yuling, Jiang Zhi, Zhou Zhengong, et al. Acoustic emission analysis of carbon fiber reinforced polymer
- bolted joints damage process under tensile load[J]. Acta Materiae Compositae Sinica, 2019, 36(8): 1854–1863.
  [3] 党轩, 谷丰收, 王铁, 等. 基于声发射的柴油机连杆大端轴瓦 碰撞摩擦故障诊断[J]. 振动与冲击, 2018, 37(19): 205–210. Dang Xuan, Gu Fengshou, Wang Tie, et al. Collision friction fault diagnosis for diesel engine connecting rod big
- end bearing bush based on acoustic emission[J]. Journal of Vibration and Shock, 2018, 37(19): 205–210.
  [4] 简克彬, 王宁, 黎启胜, 等. 独管塔模型与底板螺栓连接状
- 态的声发射辨识试验方法研究 [J]. 西南科技大学学报, 2013, 28(3): 45-49.

Jian Kebin, Wang Ning, Li Qisheng, et al. Study of bolted joint condition of single pipe tower model and the base plate using acoustic emission identification experiment methods[J]. Journal of Southwest University of Science and Technology, 2013, 28(3): 45–49.

- [5] 张健奎, 王宁, 卢萍, 等. 辨识振动环境中两点螺栓连接状态的 REE 声发射指标 [J]. 振动与冲击, 2013, 32(8): 179–182. Zhang Jiankui, Wang Ning, Lu Ping, et al. AE REE index to identify connecting state of a 2-bolt connected structure[J]. Journal of Vibration and Shock, 2013, 32(8): 179–182.
- [6] 张陆佳,林兰天,陈春敏,等.基于主成分分析的纤维拉伸断 裂声发射信号识别 [J]. 纺织学报, 2018, 39(1): 19-24. Zhang Lujia, Lin Lantian, Chen Chunmin, et al. Identification of fiber tensile fracture acoustic emission signal based on principal component analysis[J]. Journal of Textile Research, 2018, 39(1): 19-24.
- [7] Vongserewattana N, Suwansin W, Phasukkit P, et al. Validation of acoustic emission railway track crack analysis using MFCC[C]// 2019 16th International Conference on Electrical Engineering/Electronics, Computer, Telecommunicationsand Information Technology (ECTI-CON), IEEE, 2019: 633–636.
- [8] 司莉,毕贵红,魏永刚,等. 基于 RQA 与 SVM 的声发射信号 检测识别方法 [J]. 振动与冲击, 2016, 35(2): 97–103, 123.
  Si Li, Bi Guihong, Wei Yonggang, et al. Detection and identification of acoustic emission signals based on recurrence quantification analysis and support vector machines[J]. Journal of Vibration and Shock, 2016, 35(2): 97–103, 123.
- [9] Shin H C, Roth H R, Gao M, et al. Deep convolutional neural networks for computer-aided detection: CNN architectures, dataset characteristics and transfer learning[J]. IEEE Transactions on Medical Imaging, 2016, 35(5): 1285–1298.
- [10] Babu G S, Zhao P, Li X L. Deep convolutional neural network based regression approach for estimation of remaining useful life[C]. International Conference on Database Systems for Advanced Applications. Springer, Cham, 2016: 214–228.

- [11] Jung B H, Kim Y W, Lee J R. Laser-based structural training algorithm for acoustic emission localization and damage accumulation visualization in a bolt joint structure[J]. Structural Health Monitoring, 2019, 18(5/6): 1851–1861.
- [12] Zhang Y, Sun X, Loh K J, et al. Autonomous bolt loosening detection using deep learning[J]. Structural Health Monitoring, 2020, 19(1): 105–122.
- [13] Zhao X, Zhang Y, Wang N. Bolt loosening angle detection technology using deep learning[J]. Structural Control and Health Monitoring, 2019, 26(1): e2292.1–e2292.14.
- [14] 黄金, 吴庆良, 陈钒. 基于 CEEMDAN-WPT 联合去噪的灾后求救信号能量分布特征研究 [J]. 南京理工大学学报 (自然科学版), 2020, 44(2): 194-201.
  Huang Jin, Wu Qingliang, Chen Fan. Study on energy distribution character about post-disaster rescue signal based on CEEMDAN-WPT denoising[J]. Journal of Nanjing University of Science and Technology, 2020, 44(2): 194-201.
- [15] 陆彦希,曹乐.基于改进 CEEMDAN 和 TEO 的轴承故障特 征提取方法 [J].噪声与振动控制, 2020, 40(2): 109–114.
  Lu Yanxi, Cao Le. Bearing fault feature extraction method based on improved CEEMDAN and TEO[J].
  Noise and Vibration Control, 2020, 40(2): 109–114.
- [16] Ai O C, Hariharan M, Yaacob S, et al. Classification of speech dysfluencies with MFCC and LPCC features[J]. Expert Systems with Applications, 2012, 39(2): 2157–2165.
- [17] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[J]. arXiv preprint, arXiv: 1409.1556, 2014.
- [18] San-Segundo R, Gil-Martín M, D'Haro-Enríquez L F, et al. Classification of epileptic EEG recordings using signal transforms and convolutional neural networks[J]. Computers in Biology and Medicine, 2019, 109: 148–158.