

DOI: 10.19783/j.cnki.pspc.231422

考虑声-振模态结合的抽水蓄能机组轴承故障诊断

胡列豪¹, 巩宇^{1,2}, 张勇军¹, 安禹铮¹, 蒋崇颖¹, 廖美英³

(1. 华南理工大学电力学院, 广东 广州 510641; 2. 南方电网储能股份有限公司, 广东 广州 510635;
3. 广东科学技术职业学院, 广东 广州 510600)

摘要: 为解决抽水蓄能机组轴承磨损故障难以监测和识别的问题, 提出一种结合声振数据的双模态神经网络机组轴承诊断模型。首先分析了抽水蓄能机组声振特性, 融合相似软阈值对奇异值分解去噪方法进行改进, 有效消除非接触式传感器固有噪声干扰。其次提出逆巴克频谱变换方法, 并结合巴克频谱变换和格拉姆角和场变换等特征工程技术, 提取机组轴承的声纹和振动特征图。通过融合相对位置编码的自注意力机制和深度可分离卷积, 建立特征图传递网络。同时运用多头自注意力机制和双向长短期记忆网络搭建了时序数据传递网络, 并以平行网络架构构建了机组轴承故障诊断模型。实验对比分析表明, 所提方法具有较高的故障识别准确率, 为抽水蓄能电站机组轴承监测问题提供了有效的解决途径。

关键词: 抽水蓄能机组; 声-振模态; 奇异值分解; 特征工程; 故障诊断

Pumped storage unit bearing fault diagnosis with a combination of sound and vibration dual-modal

HU Lichao¹, GONG Yu^{1,2}, ZHANG Yongjun¹, AN Yuzheng¹, JIANG Chongying¹, LIAO Meiyong³

(1. School of Electric Power, South China University of Technology, Guangzhou 510641, China; 2. China Southern Power Grid Energy Storage Co., Ltd., Guangzhou 510635, China; 3. Guangdong Polytechnic of Science and Technology, Guangzhou 510600, China)

Abstract: To address the problem of difficult monitoring and identification of a bearing wear damage fault in pumped storage unit, a dual-modal neural network model for unit bearing diagnosis that combines sound and vibration data is proposed. First, the sound and vibration characteristics of the unit are analyzed, and a soft threshold is combined to improve the singular value decomposition (SVD) denoising method. This effectively eliminates inherent noise interference from the non-contact sound sensor. In addition, an inverse Bark spectrum transform method is proposed, and combining with feature engineering technology such as the Bark spectrum transform and Gram's angle summation field (GASF) transform, the sound and vibration feature map of the unit bearing is extracted. A feature map propagation network is established using a self-attention mechanism with relative position encoding and depth-wise separable convolution. Simultaneously, a time series data propagation network is constructed using a multi-head self-attention mechanism and a bidirectional long short-term memory network (BiLSTM). These components are integrated into a parallel architecture to build a fault diagnosis model for the unit bearing. Comparative analysis of results shows that the proposed method has high accuracy in fault recognition, providing an effective solution to the unit bearing monitoring problem in pumped storage power stations.

This work is supported by the National Natural Science Foundation of China (No. 52177085).

Key words: pumped storage unit; sound-vibration modal; singular value decomposition (SVD); feature engineering; fault diagnosis

0 引言

随着“双碳”目标持续推进, 海上风电等大规模

模新能源并网带来显著的波动性, 抽水蓄能作为能源转型的关键要素, 迎来了大规模发展机遇^[1-3]。抽水蓄能电站涵盖了油气水电等众多大型设备, 作为承担调峰任务的主设备, 其机组正常稳定工作是电站发挥作用的基础, 机组状态监测和故障诊断则是判断设备正常运行的关键手段。抽蓄机组在实际运

基金项目: 国家自然科学基金项目资助(52177085); 广东省重点领域研发计划项目资助(2021B0101230001)

行期间都会产生振动，一旦部件出现松动则会使导叶和轴承接口处产生剧烈磨损，严重时将导致轴承损坏^[4]。抽蓄机组频繁启停且不同工况中长时间运行，其轴承部位极易产生疲劳磨损，从而引发停机故障。

近年来人工智能技术不断取得突破，在设备状态感知和故障诊断中提供更为强大的技术支持^[5-6]。目前主流轴承故障诊断技术以机器学习为主，提取信号深度特征可以有效识别出故障或缺陷。文献[7]关注风力发电机组轴承的振动信号，提出了自适应小波变换的特征提取方法。文献[8]结合变分模态分解和熵计算重构振动特征，对极限梯度提升方法的超参数进行优化，实现电动机多类型轴承故障诊断。文献[9-11]对传统卷积神经网络进行改进，提取信号特征完成设备故障诊断。文献[12]利用最小冗余相关性得到振动信号的无量纲指标，利用支持向量机 (support vector machine, SVM) 进行故障识别。上述方法在设备故障诊断中取得了良好的效果，但没有考虑抽水蓄能机组实际生产过程中不同工况复杂场景，如机组存在发电工况和泵工况等运行工况。

当前多数故障诊断方法仍是单类型信号诊断，存在信息量有限和噪声干扰等局限。结合不同模态数据实现设备异常识别是故障诊断领域的重要研究方向，一方面模态结合的方法考虑了设备不同数据之间的相关性，另一方面多个数据测点则可以覆盖设备更大的监测范围。然而，如何去融合来自多类型传感器的不同尺度数据仍是一个重要的挑战。文献[13]融合了多类型数据并用神经网络提取更深层次的特征，凸显了故障诊断网络融合多类型数据的有效性。文献[14-16]融合了电气设备声振信号实现状态感知或故障诊断，采取原始数据特征提取的方法提升机器学习模型的故障识别效果。文献[17]利用变分模态分解进行特征提取，通过一维卷积神经网络进行故障检测，提高了识别准确率。

显然，基于不同模态的数据，机器学习技术可以有效地对设备进行故障诊断。本文以装设在某抽水蓄能电站水车室中的声音传感器和机组轴承上振动传感器采集到的现场声音与振动数据为基础，提出了一种声-振模态结合的故障诊断神经网络模型。首先为了消除非接触式声音传感器采集时存在的固有噪声，利用相似软阈值对奇异值分解^[18]进行改进，通过实验验证了该方法的去噪效果。然后提出逆巴克频谱变换方法，并结合特征工程中的巴克频谱变换^[19]来获取声音频谱图，通过格拉姆角和场变换方法^[20]得到振动角和场图，以此构成声振特征图集。进而提出了融合相对位置编码的自注意力机制，

利用深度可分离卷积^[21]的学习优势建立特征图传递网络，并结合多头自注意力机制^[22]和双向长短期记忆网络^[23]搭建了双模态并行神经网络结构。最后通过对比实验验证了所提模型的有效性和准确性。

1 抽水蓄能机组声振特性分析

为实时获取抽水蓄能机组的状态信息，在抽水蓄能电站中的水车室装设了声音传感器，监测发电机组运行在泵工况和发电工况的声音波形变化，利用快速傅里叶变换获取信号的主频信息，机组运行声音波形及频率分布如图 1 所示。

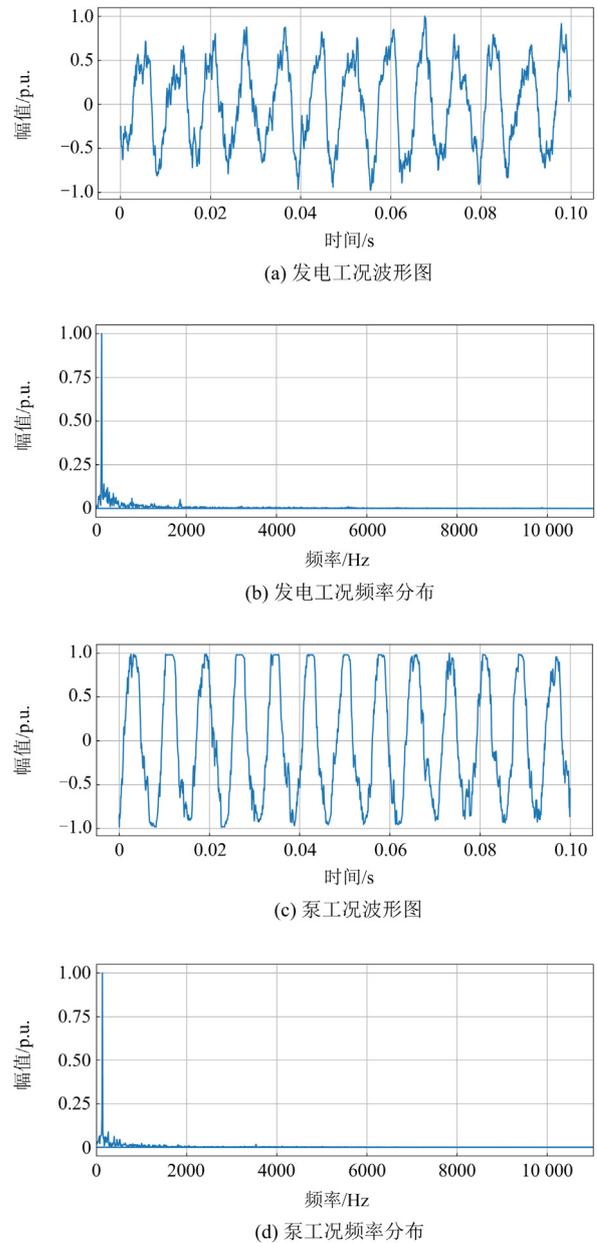


图 1 机组声音波形及频率分布

Fig. 1 Sound waveform and spectrum distribution of unit

如图 1 所示, 图 1(a)和图 1(c)分别为抽水蓄能机组运行在发电工况和泵工况时的声音波形图, 图 1(b)和图 1(d)分别为抽水蓄能机组运行在发电工况和泵工况时的声音频率分布。图中机组声音具有较多纹波噪声, 主要是装设在水车室的非接触式传感器在采集声音过程中产生的固有噪声, 发电工况波形与泵工况波形有明显差别, 发电工况波形具有更多的纹刺, 声音主频均为 130 Hz, 次主频为 120 Hz。

收集机组轴承磨损故障时的声音数据, 利用快速傅里叶变换进行频谱分析, 轴承磨损故障运行声音波形及频率分布如图 2 所示。

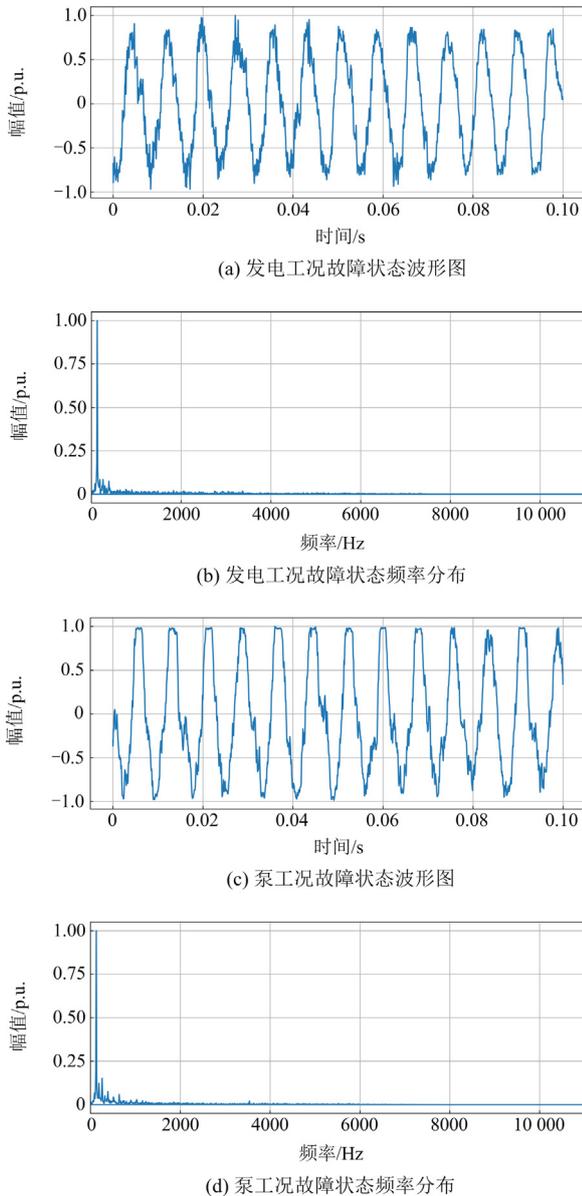


图 2 轴承磨损故障的声音波形及频率分布

Fig. 2 Sound waveform and spectrum distribution of unit bearing wear fault

如图 2 所示, 图 2(a)和图 2(c)分别为抽水蓄能机组轴承磨损故障时运行在发电工况和泵工况时的声音波形图, 图 2(b)和图 2(d)分别为抽水蓄能机组轴承磨损故障时运行在发电工况和泵工况时的声音频率分布。在发生轴承磨损故障之后, 声音波形和频谱出现略微变化, 主频仍为 130 Hz, 次主频为 120 Hz。轴承故障前后声音数据的变化主要集中于频率分布的非主频部分, 本文提出逆巴克频谱变换方法来捕捉在声音频谱上更为明显的特征。

对于声音数据数学模型, 通常采用平面波方程、声速方程和声强进行描述, 如式(1)一式(3)所示。

$$P_r(P_x, t) = P_{r, \max} \sin(\varepsilon P_x - \omega_p t + \phi_p) \quad (1)$$

$$v_p = \frac{\omega_p}{\varepsilon} \quad (2)$$

$$Y_p = \frac{1}{2} \rho v_p \omega_p^2 P_{r, \max}^2 \quad (3)$$

式中: P_r 为声压; $P_{r, \max}$ 为最大声压; ε 为波数; P_x 为位移; t 为时间; ω_p 为声波的角频率; ϕ_p 为相位; v_p 为声速; ρ 为介质密度; Y_p 为声强。

根据上述数学模型可以得到声音的基本特性, 采用平面波方程对声音波形进行拟合较为理想化, 难以实际应用, 本文方法以传感器直接采集到的机组声音数据为基础并结合特征提取和神经网络实现故障诊断。

抽水蓄能机组水导轴承上装设了 X 向和 Y 向振动传感器测点, 可直接采集振动数据, 如图 3 所示。

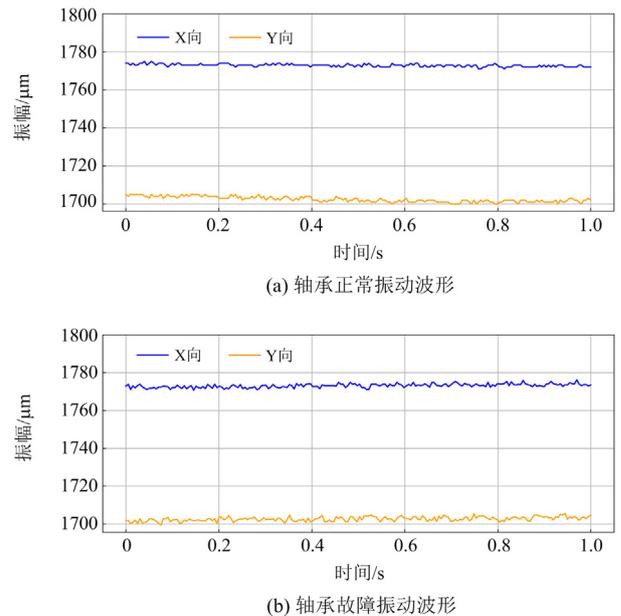


图 3 机组轴承振动波形

Fig. 3 Vibration waveform of unit bearing

由图 3 可知, 机组运行时轴承振幅较小, 在 $5 \mu\text{m}$ 之内变化, 而 X 向振动幅值相对 Y 向偏大。一旦发生缺陷或故障, 轴承振动情况会出现变化, 如图 3(b) 所示。当机组轴承发生磨损故障时, 振动波形变化微小, 机组监控系统通过阈值进行判断的准确率不高, 因此本文采用特征工程中的格拉姆角和场变换方法提取更为明显的特征。

对于振动数学模型, 通常采用简谐振动方程进行描述, 表示为

$$Z_x(t) = Z_{\max} \sin(\omega_z t + \phi_z) \quad (4)$$

式中: Z_x 为振动幅值; Z_{\max} 为最大振幅; ω_z 为振动的角频率; ϕ_z 为振动相位。

通过上述数学模型可获得振动的基本特性。而本文采用的方法是直接收集轴承振动数据, 并利用特征提取和构建网络模型实现故障诊断。

由于轴承磨损故障在声音和振动数据上的变化微小, 通过逆巴克频谱变换、巴克频谱变换和格拉姆角和场的特征提取方式来提取数据特征, 从而提升诊断模型识别的准确率。

2 融合相似软阈值的奇异值分解

监控机组运行状态的声音传感器设置在水车室内, 对比接触式声音传感器采集的声音数据, 非接触式声音传感器在采集过程中会出现噪声, 为了消除采集噪声对故障诊断的影响, 首先对声音进行去噪处理。本文提出了一种融合相似软阈值的奇异值去噪算法, 利用 Pearson 相似度^[24]计算声音相似度, 并将其作为奇异值分解的阈值, 最终执行奇异值分解与重构实现声音去噪。

2.1 奇异值分解与重构

在矩阵计算中, 通过矩阵分解得到矩阵的奇异值, 将有效奇异值保留、剩余奇异值置零, 再进行矩阵重构实现声音去噪。首先进行标准化计算, 表示为

$$\hat{S} = \frac{S - S_{\min}}{S_{\max} - S_{\min}} \quad (5)$$

式中: \hat{S} 为声音标准化信号; S 为声音原始信号; S_{\max} 、 S_{\min} 分别为声音原始信号的最大振幅值、最小振幅值。

然后将标准化后的声音信号转化为轨迹矩阵, 矩阵中的元素表示为

$$a_{p,q} = \hat{S}_{(p-1)l+q} \quad (6)$$

式中: $a_{p,q}$ 为轨迹矩阵中第 p 行第 q 列的元素; l 为窗口大小。

根据奇异值分解原理, 任意矩阵都可以表示为正交矩阵、对角矩阵和另一个正交矩阵转置的乘积。

通过奇异值分解将轨迹矩阵分解为多个矩阵之和。

$$A = M \times S_{\text{diag}} \times N \quad (7)$$

式中: A 为轨迹矩阵; M 为正交矩阵; S_{diag} 为对角矩阵; N 为另一个正交矩阵的转置。

为了得到可以有效去噪的关键奇异值分量, 利用阈值置零的方式进行提取。

$$\lambda_{\text{SVD}} = \begin{cases} S_{\text{diag}}(u) & S_{\text{diag}}(u) \leq \mu \\ 0 & S_{\text{diag}}(u) > \mu \end{cases} \quad u = 1, 2, \dots, N_{\text{diag}} \quad (8)$$

式中: λ_{SVD} 为关键奇异值分量; $S_{\text{diag}}(u)$ 为第 u 个奇异值; μ 为 Pearson 相似度阈值; N_{diag} 为奇异值的总数。

最后利用轨迹矩阵重构与计算反对角元素均值得到降噪序列 S_{de} 。

2.2 相似软阈值计算

本文将声音序列信号的相似度作为奇异值降噪的阈值, 从而对奇异值分解降噪方法进行改进。首先通过傅里叶变换得到声音序列的周期, 将声音序列根据周期进行切分得到 \bar{S}_i , 并利用 Pearson 相似度计算得到声音序列的相似度, Pearson 相似度的计算公式为

$$\mu = \frac{V_{\bar{S}_i, \bar{S}'_i}}{\sqrt{V_{\bar{S}_i, \bar{S}_i} \times V_{\bar{S}'_i, \bar{S}'_i}}} \quad (9)$$

式中: $V_{\bar{S}_i, \bar{S}'_i}$ 为声音序列 \bar{S}_i 和 \bar{S}'_i 的协方差; $V_{\bar{S}_i, \bar{S}_i}$ 为声音序列 \bar{S}_i 的方差; $V_{\bar{S}'_i, \bar{S}'_i}$ 为声音序列 \bar{S}'_i 的方差。

3 基于特征工程的声振特征变换提取

抽水蓄能机组运行声音和振动信号是一种非平稳非线性的时序序列, 为了更好地捕捉机组运行声纹和振动特征, 同时还考虑到特征工程技术中的频谱变换和角场变换方法对于提取时序数据特征的高适应度和有效性, 本文提出逆巴克频谱变换方法, 并融合巴克频谱变换提取机组轴承运行声纹特征, 另外采用格拉姆角和场变换提取机组轴承的运行振动特征, 将特征组合在一起构成声振特征图。

3.1 巴克频谱变换与逆变换

巴克标度(Bark scale)是由 Terhard 和 Zwicker 基于心理声学研究成果提出的, 巴克频谱变换通过巴克标度和频谱分析结合来提取深层次声音特征, 用于模拟人类听觉系统对声音的感知。巴克频谱变换将频谱感知线性预测系数与傅里叶变换相结合, 得到巴克倒谱系数(bark frequency cepstral coefficients, BFCC)。与梅尔倒谱系数计算一样, 采用相同的步骤, 涉及计算滤波器组、预加强、加窗、应用快速

傅里叶变换计算功率谱。不同之处在于巴克频谱变换不使用梅尔标度, 而是使用巴克标度来映射信号的频谱。

Bark scale 的等级范围为 1~24, 分别对应于人耳听觉的前 24 个临界波段, 频率波段对应的巴克标度转换公式为

$$B_f = 6 \times \ln \left(\frac{f}{600} + \sqrt{\left(\frac{f}{600} \right)^2 + 1} \right) \quad (10)$$

式中: B_f 为 Bark 标度; f 为频率。

由此可以得出 Bark 滤波器的组成, 见图 4(a)。在确定 Bark 滤波器组之后, 还需要对信号进行处理, 包括预增强、加窗、傅里叶变换, 如式(11)~式(13)所示。

$$S'_{de}(t) = S_{de}(t) + \alpha S_{de}(t-1) \quad (11)$$

式中: $S'_{de}(t)$ 为预增强后的声音信号; α 为阈值。

$$S_w(t, L, w_s) = S'_{de}(t) \times \text{ham}_L(t - n w_s) =$$

$$S'_{de}(t) \times \left(0.54 - 0.46 \cos \frac{2\pi(t - n w_s)}{L} \right) \quad (12)$$

式中: $S_w(t, L, w_s)$ 为应用汉明窗函数后的声音信号; L 为窗口长度; w_s 为窗口步进量; n 为窗口的索引; $\text{ham}_L()$ 为汉明窗函数。

$$F(k) = \sum_{m=0}^{N_s-1} S_w(m) \cdot e^{-j2\pi \frac{km}{N_s}} \quad (13)$$

式中: $F(k)$ 为声音的频域信号; k 为频率分量索引; $S_w(m)$ 为声音时域信号在离散时间点 m 处的样本值; N_s 为总离散时间数。

最后将功率谱与滤波器组相乘得到巴克倒谱系数。

$$\mathbf{B}_{\text{BFCC}} = |F(k)|^2 \times \mathbf{B}_{\text{Ba}}^T \quad (14)$$

式中, \mathbf{B}_{BFCC} 和 \mathbf{B}_{Ba} 分别为巴克倒谱系数与巴克滤波器组。

巴克滤波器在低频段展现出更好的分辨效果, 为了更好地凸显声音信号在高频段的特征, 本文参考频谱变换方法, 提出了逆巴克频谱变换: 通过滤波器组在高频和低频的交换构建逆巴克滤波器组, 然后经过预加强、加窗、应用快速傅里叶变换计算功率谱, 最终得到逆巴克倒谱系数(inverse bark frequency cepstral coefficients, IBFCC), 逆巴克滤波器组如图 4(b)所示。

3.2 格拉姆角和场变换

利用电站监控系统中的振动传感器得到轴承 X 向和 Y 向的振动信号, 原始振动信号是时序数据, 本文采用格拉姆角和场(Gram's angle summation field, GASF)变换方法进一步凸显振动特征。GASF 变换

是一种将时序数据转换成二维图像的数据处理方法, GASF 计算利用余弦函数角度和完成二维数据变换, 最后构成角和场图。

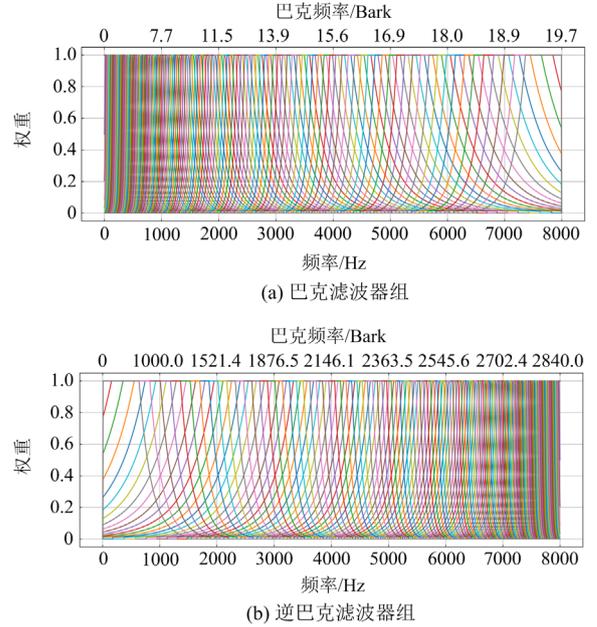


图 4 机组声音滤波器组

Fig. 4 Filter banks of unit sound

首先标准化振动时序数据, 然后计算每 2 个时间点之间的反余弦角度, 最后将其转化为角度和, 构成角和场图, 角和场图矩阵的元素由式(15)得到。

$$g_{p,q} = \cos(\arccos(\hat{D}_p) + \arccos(\hat{D}_q)) \quad (15)$$

式中: $g_{p,q}$ 为角和场图矩阵中第 p 行第 q 列的元素; \hat{D}_p 和 \hat{D}_q 为标准化后的振动时序信号。

4 双模态并行架构的轴承故障诊断模型

由上述特征工程技术得到了声音信号和振动信号的二维特征, 考虑原始时序数据的连续性, 将声振信号二维特征图和原始时序作为网络的双模态输入, 搭建深度可分离卷积模块与双向长短期模块的并行神经网络, 利用 Sharedneck 结构进行合并, 最后输出故障识别结果。

4.1 融合相对位置编码的自注意力机制

自注意力机制利用矩阵变换和折叠等运算得到注意力得分, 得分叠加在原始图像上可以凸显数据的潜在特征, 其实用效果得到了检验^[25]。首先基于线性变换将输入向量 \mathbf{X} 分成 \mathbf{Q} 、 \mathbf{K} 、 \mathbf{R} 矩阵, 然后将相对位置编码 G_{Re} 加入到注意力得分的计算中, 即

$$J_{\text{SA}}(\mathbf{Q}, \mathbf{K}, \mathbf{R}) = \text{Softmax} \left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d}} + G_{\text{Re}} \right) \mathbf{R} \quad (16)$$

式中: $J_{SA}(\cdot)$ 为融合相对位置编码的自注意力操作; d 为矩阵维度; G_{Re} 为相对位置编码; $\text{Softmax}(\cdot)$ 为归一化指数函数。

4.2 多头自注意力机制

在缩放点积注意力的基础上进一步发展得到多头自注意力机制, 通过增加多个子空间(即“头”), 实现 Q 、 K 、 R 矩阵不同的线性变换表示。将所有子空间的输出进行拼接, 得到最终多头注意力机制的输出, 计算公式见式(17)一式(19)。

$$J_{SDPA}(Q, K, R) = \text{Softmax}\left(\frac{QK^T}{\sqrt{d}}\right)R \quad (17)$$

$$H_i = J_{SDPA}(W_{Q,i}Q, W_{K,i}K, W_{R,i}R) \quad (18)$$

$$M_{MH}(Q, K, R) = W_{CO} \cdot \text{Con}(H_1, H_2, \dots, H_{N_{\text{head}}}) \quad (19)$$

式中: $J_{SDPA}(\cdot)$ 为缩放点积注意力操作; H_i 为第 i 个子空间的注意力操作; N_{head} 为子空间总数; $W_{Q,i}$ 、 $W_{K,i}$ 、 $W_{R,i}$ 分别为计算 Q 、 K 、 R 的权重矩阵; $M_{MH}(\cdot)$ 为多头注意力操作; $\text{Con}(\cdot)$ 为拼接操作; W_{CO} 为拼接操作的权重矩阵。

通过多头注意力机制可以有效挖取时序数据中潜在的时间依赖关系, 特别是在长时序数据中, 多头注意力的不同子空间可以学习到不同时间尺度的特征和模式, 提高网络整体的准确度。

4.3 深度可分离卷积

深度可分离卷积的设计思想是基于数据在通道和空间上的可分离性, 而由巴克频谱变换、逆巴克频谱变换以及格拉姆角和场变换的方法得到的声振特征图, 是属于互相解耦且来源相关的特征图, 采用深度可分离卷积模型可以更好地适应于声振特征从而提高网络的识别准确率。在深度可分离卷积模块中采用了深度卷积和逐点卷积分别进行计算, 表示为

$$o_{DS}(x_p, x_q, c) = \sum_{\tau=1}^{N_\tau} \left(\sum_{e=1}^{N_E} X_c(x_p, x_q) \delta_e \right) \delta_\tau \quad (20)$$

式中: $o_{DS}(x_p, x_q, c)$ 表示深度可分离卷积在输入 X_c 第 c 通道位置 (x_p, x_q) 处的值; δ_e 为第 e 个深度卷积核; δ_τ 表示第 τ 个逐点卷积核; N_τ 为逐点卷积核数量; N_E 为深度卷积核数量。

4.4 双向长短期记忆网络

双向长短期记忆网络是循环神经网络的一种变体形式, 对时序数据特别是长时间序列有着更好的学习性能。在循环过程中加入了遗忘门的计算, 同时融入了从后向往前时序信息的计算, 获得了更好的特征捕获效果。在前向 LSTM 的计算中主要包括遗忘门、输入门、记忆单元 Cell、输出门的状态更新。

定义整个前向 LSTM 的计算公式表示为

$$\psi_t = o_t \odot \tanh(\zeta_{me,t}) \quad (21)$$

$$o_t = \text{sig}(W_o \cdot [\psi_{t-1}, X_t] + b_o) \quad (22)$$

式中: ψ_t 为前向 LSTM 在 t 时刻的输出; o_t 为输出门在 t 时刻的输出; $\text{sig}(\cdot)$ 表示 sigmoid 激活函数; W_o 为输出门的权重矩阵; X_t 为 t 时刻的输入; b_o 为输出门的偏置; $\zeta_{me,t}$ 为 t 时刻的记忆单元值。

记忆单元值需要根据时间步进行更新, 即

$$\zeta_{me,t} = \gamma_{fo,t} \odot \zeta_{me,t-1} + I_t \odot \beta_t \quad (23)$$

$$\beta_t = \tanh(W_\beta \cdot [\psi_{t-1}, X_t] + b_\beta) \quad (24)$$

式中: $\zeta_{me,t-1}$ 为前一时刻的记忆单元值; I_t 为输入门在 t 时刻的输出; β_t 为过程变量; $\gamma_{fo,t}$ 为遗忘门在 t 时刻的输出; W_β 为计算新记忆单元的权重矩阵; b_β 为计算新记忆单元值的偏置。

输入门决定了当前时刻的输入数据有多少可以保存到记忆单元, 遗忘门则决定了记忆单元中信息有多少可以保留到下一时刻, 具体计算公式为

$$I_t = \text{sig}(W_I \cdot [\psi_{t-1}, X_t] + b_I) \quad (25)$$

$$\gamma_{fo,t} = \text{sig}(W_{fo} \cdot [\psi_{t-1}, X_t] + b_{fo}) \quad (26)$$

式中: W_I 为输入门的权重矩阵; b_I 为输入门的偏置; W_{fo} 为遗忘门的权重矩阵; b_{fo} 为遗忘门的偏置。

在后向 LSTM 的计算中, 通过输入反向的时序信号, 得到后向 LSTM 输出。将前向 LSTM 输出与后向 LSTM 输出拼接得到双向长短期记忆网络输出。

4.5 双模态并行架构设计

由 4.1—4.4 节得到了融合相对位置编码的自注意力机制、深度可分离卷积、多头注意力机制和双向长短期网络的单独封装模块, 将模块进行拼接组合得到双模态并行架构, 具体如图 5 所示。

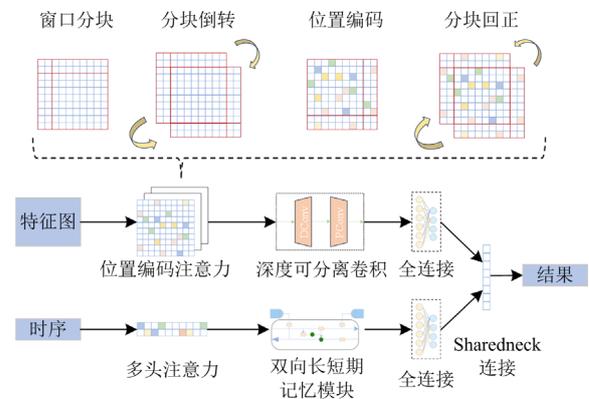


图 5 声-振模态并行网络架构图

Fig. 5 Sound-vibration modal parallel network architecture

在本文设计的声-振双模态并行结构中,融合相对位置编码的自注意力机制增加了窗口分块、分块倒转和分块回正的操作,主要是增加特征表达形式,给卷积操作提供更多维度的特征以实现更好的学习效果。

5 算例分析

本文以布设在抽水蓄能电站水车室的声音传感器以及轴承振动传感器获取的声振信号为基础数据,通过融合相似软阈值的改进奇异值去噪算法对声音数据进行去噪处理,得到干净的声音样本,再通过巴克频谱变换、逆巴克频谱变换,得到声音特征巴克频谱和逆巴克频谱。振动传感器收集的轴承振动数据经过简单数据清洗排除异常数据,通过格拉姆角和场变换得到振动特征 GASF 图。

5.1 改进奇异值去噪效果分析

利用本文提出的融合相似软阈值的改进奇异值去噪算法对声音数据进行处理,并与常见的小波分析去噪算法和经验模态分解算法进行对比,去噪效果如图 6 所示,3 种方法对应的去噪指标如表 1 所示。

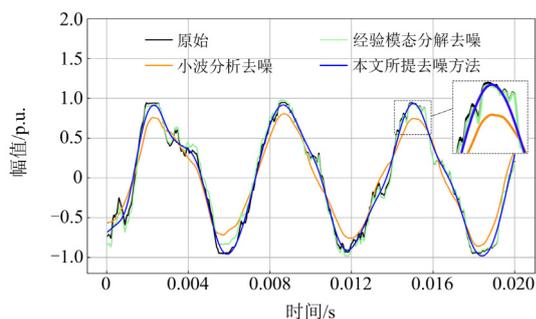


图 6 降噪效果对比

Fig. 6 Comparison of denoising effect

表 1 去噪指标对比

Table 1 Comparison of denoising indicators

方法	信噪比/dB	均方根误差	峰值信噪比/dB	频谱失真度	谐波失真度
小波分析去噪	11.80	0.029	15.50	2.80	0.066
经验模态分解	20.82	0.083	24.51	0.35	0.008
本文去噪方法	17.74	0.042	21.43	0.71	0.017

从图 6 可以看出,本文提出的改进奇异值分解去噪算法减少了原始波形的纹刺,降低采集过程中的谐波含量。相比小波分析去噪和经验模态分解去噪,经验模态分解去噪保留了较多噪声,而小波分析去噪则消去更多信号特征,本文提出的去噪方法

保留了相关特征,具有较好的去噪效果。在信噪比、均方根误差、峰值信噪比、频谱失真度、谐波失真度方面,本文方法比小波分析方法有更好的去噪表现,而经验模态分解的指标较好,原因在于其更加贴合原曲线,没有起到数据去噪的作用。

5.2 声纹特征和振动特征提取效果分析

由 3.1 节的方法可以得到机组声音的巴克频谱和逆巴克频谱图,如图 7 所示。

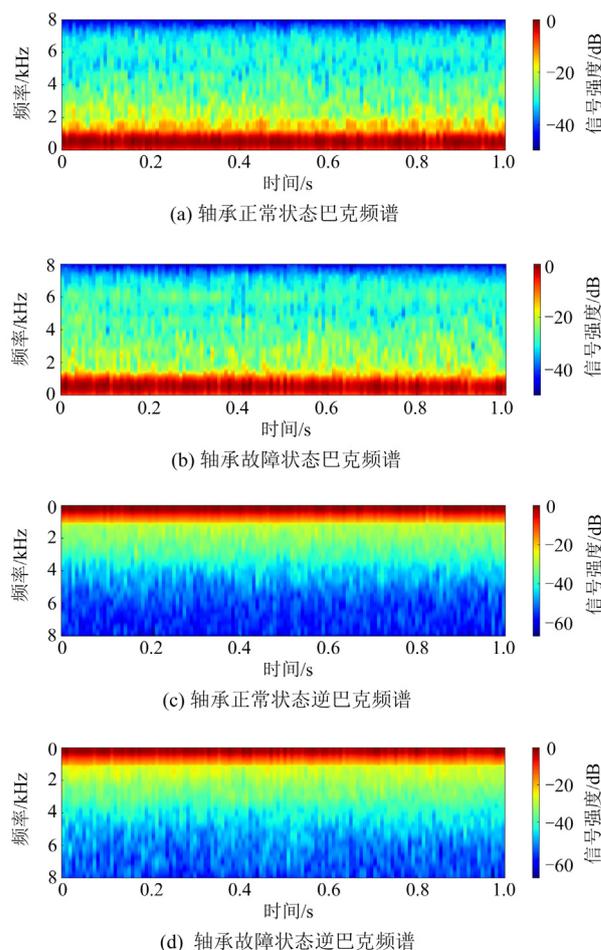


图 7 机组声音频谱图

Fig. 7 Spectrum of unit bearing sound

从图 7 中可以看出,巴克频谱可以更好地展示低频段的频谱变化情况,而逆巴克频谱则可以更好地展示在高频段的频谱变化。从图 7(a)及图 7(b)的对比可以看出,轴承故障在 1~6 kHz 范围内有能量起伏变化,磨损故障状态下能量变化范围更大,结合图 7(c)及图 7(d)的中高频段分布可知,轴承故障时的频谱能量往中高频有所偏移,产生了中高频的谐波。

对于采集到的振动数据,采用 3.2 节格拉姆角和场方法进行特征提取。图 8 为抽水蓄能机组轴承振动格拉姆角和场图,通过格拉姆角和场变换,将

原来一维振动信号放大为二维特征图，可以更好地发现振动信号的微小变化。从图 8(b)的颜色变化可以看到轴承故障后振幅波动增大，图中明暗变化更多，结合神经网络对二维图像的计算识别能力，格拉姆角和场变换可以有效提升网络的准确率。

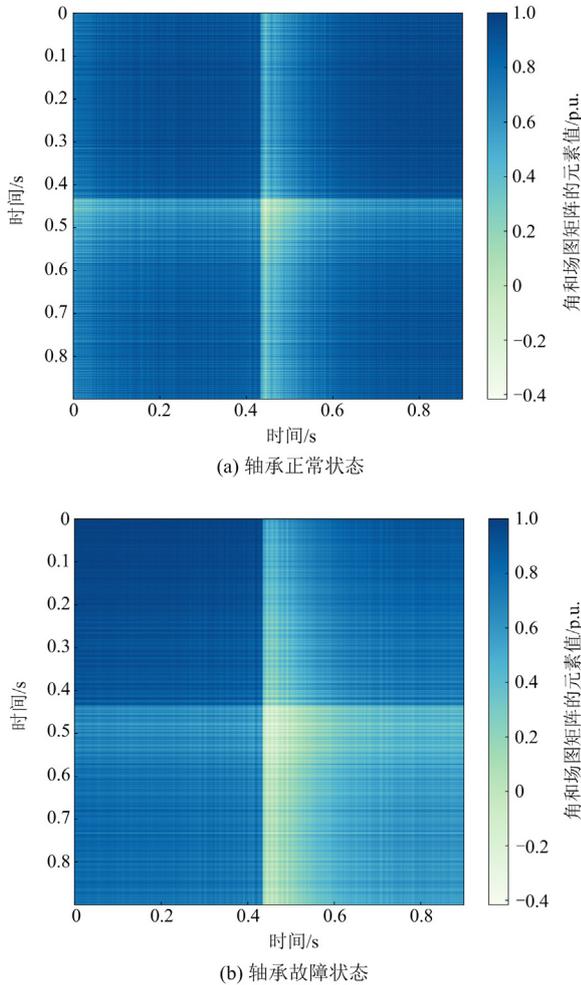


图 8 机组轴承格拉姆角和场图

Fig. 8 Gram's angle summary field of unit bearing

5.3 双模态并行网络识别效果分析

抽水蓄能电站机组启停频繁，经常运行在发电工况或泵工况，在现场机组稳定运行时进行声振数据采集，针对这两种常规状态直接现场收集声音振动数据。抽水蓄能电站实际水导轴承振动传感器类型为华科同安 TVS-201，水车室非接触式声音振动传感器类型为海康威视 DS-2MC1001-W。每条时序数据采集时长为 1 s，采样频率为 16 kHz。针对水导轴承磨损故障数据难以直接采集的问题，采用文献[26]的数据增强方法并结合现场模拟和轴承振动磨损故障数据集，得到故障数据集。

由于振动传感器直接固定在机组轴承上，振动

数据不用进行去噪只需做数据异常清洗。利用改进奇异值去噪之后的声音时序数据与振动数据组成时序数据组，利用特征工程技术得到的声振特征图组合构成特征图组，形成包含泵工况、发电工况、泵工况轴承故障状态、发电工况轴承故障状态的声振数据集，其中训练集、测试集、验证集的比例为 3:1:1，每个类别分别有 1000 条样本。该数据集包含有可能发生的抽水蓄能轴承磨损故障，并囊括了抽水蓄能机组的绝大部分工况，包括抽水蓄能机组发电工况和泵工况运行数据以及轴承磨损故障数据，数据分布与实际场景相匹配，具有均衡性及代表性。

在构筑了混合声振数据集后，将时序数据组和特征图组作为双模态并行网络的输入。同时对比朴素贝叶斯分类、SVM 和一维卷积神经网络(one-dimensional convolutional neural network, 1D-CNN)方法^[16]的识别准确率，朴素贝叶斯分类和 SVM 模型的输入为声振特征图组及时序数据组，1D-CNN 模型输入只有时序数据，在训练数据集打乱和 50 次迭代的情况下，得到图 9 所示的识别结果。

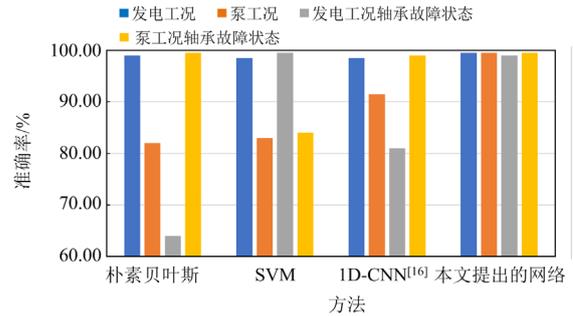


图 9 网络识别准确率

Fig. 9 Network identification accuracy

由图 9 的识别效果可以看出，本文提出的诊断网络对发电工况、泵工况、发电工况轴承磨损故障状态和泵工况轴承磨损故障状态的识别效果均较好。朴素贝叶斯、SVM 和 1D-CNN 方法^[16]对 4 种状态的总体识别准确率分别为 86.13%、91.25%和 92.50%，本文模型的识别准确率达到 99.38%。本文所提网络对 4 种不同状态均具有较高的识别准确率。可以看出，本文方法利用特征工程技术对数据进行了有效挖掘，再结合相对位置编码自注意力机制和多头注意力机制构建了深度可分离卷积和长短记忆模块融合的双模态并行网络，该网络对轴承磨损故障具有更好的识别效果。

在工程应用中，抽水蓄能电站需要布设声音传感器和振动传感器，来采集实际发电工况和泵工况

的声振数据。声音数据和振动数据经过采集后传输到服务器。在服务器上应用改进奇异值去噪算法和已训练好的故障诊断模型。将过去噪算法处理的声音数据与振动数据一起构成声振时序数据组。利用巴克频谱变换、逆巴克频谱变换以及格拉姆角和场图变换方法, 构建声振特征图。将时序数据组和声振特征图输入到训练好的故障诊断模型中, 根据得到的识别结果确定轴承是否出现磨损故障。

6 结论

针对抽水蓄能机组轴承磨损故障难以发现的问题, 同时考虑声音信号和振动信号的同源互补性, 本文提出了一种声-振模态结合的机组轴承故障诊断方法, 适用于抽水蓄能机组发电工况、泵工况、发电工况轴承磨损故障状态和泵工况轴承磨损故障状态的识别, 本文主要工作包括:

1) 为了消除机组非接触式声音传感器采集噪声的影响, 提出了一种融合相似软阈值的奇异值去噪方法, 对比小波分析去噪和经验模态分解去噪方法可知, 所提去噪方法具有较好的去噪效果;

2) 提出逆巴克频谱变换方法, 结合特征工程中的巴克频谱变换和角和场图变换, 有效提取了声振数据特征, 增加了声振数据的特征表现能力;

3) 考虑声-振模态相结合, 提出了一种双模态并行的轴承故障诊断模型, 通过实验验证了其故障诊断效果, 实际结果表明所提模型具有较高的识别准确率, 为抽水蓄能电站机组轴承故障诊断问题提供了有效的解决途径。

后续将重点研究多类型故障和多数据来源以及全过程覆盖的机组全方位状态感知。

参考文献

- [1] 国家发展改革委, 国家能源局. “十四五”新型储能发展实施方案[EB/OL]. [2022-03-22]. http://www.gov.cn/zhengce/zhengceku/2022-03/22/content_5680417.htm.
- [2] 国家能源局. 抽水蓄能中长期发展规划(2021-2035 年)[EB/OL]. [2023-04-01]. http://zfxgk.nea.gov.cn/1310193456_16318589869941n.pdf.
- [3] 郝国文, 夏斌强, 王致远, 等. 抽水蓄能 GIS 电站 VFTO 幅值影响因素与权重分析[J]. 高压电器, 2023, 59(4): 162-168.
HAO Guowen, XIA Binqiang, WANG Zhiyuan, et al. Influencing factors and weights analysis of VFTO amplitude of GIS at pumped storage power station[J]. High Voltage Apparatus, 2023, 59(4): 162-168.
- [4] 王磊, 范光宁. 大型立式水泵中的水导轴承故障分析[J]. 电子技术, 2023, 52(5): 206-207.
WANG Lei, FAN Guangning. Analysis of water guide bearing failure in large vertical pump[J]. Electronic Technology, 2023, 52(5): 206-207.
- [5] 谢小瑜, 周俊煌, 张勇军. 深度学习在泛在电力物联网中的应用与挑战[J]. 电力自动化设备, 2020, 40(4): 77-87.
XIE Xiaoyu, ZHOU Junhuang, ZHANG Yongjun. Application and challenge of deep learning in ubiquitous power internet of things[J]. Electric Power Automation Equipment, 2020, 40(4): 77-87.
- [6] 李杰, 李英昊, 张印宝, 等. 基于人工智能的监控信息事件化系统建设研究[J]. 供用电, 2022, 39(12): 17-27.
LI Jie, LI Yinghao, ZHANG Yinbao, et al. Research on the construction of monitoring information event system based on artificial intelligence[J]. Distribution & Utilization, 2022, 39(12): 17-27.
- [7] 齐咏生, 单成成, 高胜利, 等. 基于 AEWT-KELM 的风电机组轴承故障诊断策略[J]. 太阳能学报, 2022, 43(8): 281-291.
QI Yongsheng, SHAN Chengcheng, GAO Shengli, et al. Fault diagnosis strategy of wind turbines bearing based on AEWT-KELM[J]. Acta Energetica Sinica, 2022, 43(8): 281-291.
- [8] 于飞, 樊清川, 宣敏. 结合振动特征优选和 GWOA-XGBoost 的电机轴承故障诊断[J]. 国防科技大学学报, 2023, 45(3): 99-107.
YU Fei, FAN Qingchuan, XUAN Min. Motor bearing fault diagnosis by combining vibration feature optimization and GWOA-XGBoost[J]. Journal of National University of Defense Technology, 2023, 45(3): 99-107.
- [9] 王鹏程, 邓艾东, 凌峰, 等. 基于 PSO-SEBD 的风电机组滚动轴承故障诊断[J]. 振动与冲击, 2023, 42(7): 281-288.
WANG Pengcheng, DENG Aidong, LING Feng, et al. Fault diagnosis of rolling bearing of wind turbine generator based on PSO-SEBD[J]. Journal of Vibration and Shock, 2023, 42(7): 281-288.
- [10] GAO S, SHI S, ZHANG Y. Rolling bearing compound fault diagnosis based on parameter optimization MCKD and convolutional neural network[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 1-8.
- [11] HE L, YI C, ZHOU Q, et al. Fast convolutional sparse dictionary learning based on LocOMP and its application to bearing fault detection[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 22-32.
- [12] HU Q, SI X, QIN A, et al. Machinery fault diagnosis scheme using redefined dimensionless indicators and mRMR feature selection[J]. IEEE Access, 2020, 8: 40313-40326.

- [13] WAN S, LI T, FANG B, et al. Bearing fault diagnosis based on multisensor information coupling and attentional feature fusion[J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 1-13.
- [14] 马宏忠, 王健, 杨启帆, 等. 基于声振特征区分的SMA优化SVM变压器机械松动识别方法[J]. 电机与控制学报, 2023, 27(10): 42-53.
MA Hongzhong, WANG Jian, YANG Qifan, et al. SMA-optimized SVM transformer state identification method based on acoustic vibration feature differentiation[J]. Electric Machines and Control, 2023, 27(10): 42-53.
- [15] 高树国, 汲胜昌, 孟令明, 等. 基于在线监测系统与声振特征预测模型的高压并联电抗器运行状态评估方法[J]. 电工技术学报, 2022, 37(9): 2179-2189.
GAO Shuguo, JI Shengchang, MENG Lingming, et al. Operation state evaluation method of high-voltage shunt reactor based on on-line monitoring system and vibro-acoustic characteristic prediction model[J]. Transactions of China Electrotechnical Society, 2022, 37(9): 2179-2189.
- [16] 赵书涛, 王二旭, 陈秀新, 等. 声振信号联合1D-CNN的大型电机故障诊断方法[J]. 哈尔滨工业大学学报, 2020, 52(9): 116-122.
ZHAO Shutao, WANG Erxu, CHEN Xiuxin, et al. Fault diagnosis method for large motor based on sound-vibration signal combined with 1D-CNN[J]. Journal of Harbin Institute of Technology, 2020, 52(9): 116-122.
- [17] HABBOUCHE H, AMIRAT Y, BENKEDJOUH T, et al. Bearing fault event-triggered diagnosis using a variational mode decomposition-based machine learning approach[J]. IEEE Transactions on Energy Conversion, 2022, 37(1): 466-474.
- [18] 贺宇阳, 马千里, 于飞, 等. 基于CRS-LMD和SVD的MMC-HVDC线路故障测距方法[J]. 电力系统保护与控制, 2024, 52(1): 121-132.
HE Yuyang, MA Qianli, YU Fei, et al. Fault location of an MMC-HVDC line based on CRS-LMD and SVD[J]. Power System Protection and Control, 2024, 52(1): 121-132.
- [19] LIU L, LI W, WU X, et al. Infant cry language analysis and recognition: an experimental approach[J]. IEEE/CAA Journal of Automatica Sinica, 2019, 6(3): 778-788.
- [20] 齐胜, 单海鸥, 罗林, 等. 融合格拉姆角场的深度学习在痕量气体浓度识别中的应用研究[J]. 电力系统保护与控制, 2023, 51(15): 55-65.
QI Sheng, SHAN Haiou, LUO Lin, et al. Application of deep feature learning with Gram's angle field for trace gas concentration identification[J]. Power System Protection and Control, 2023, 51(15): 55-65.
- [21] CHOLLET F. Xception: deep learning with depthwise separable convolutions[C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA: 1800-1807.
- [22] 李云松, 张智晟. 基于GRU-TGTransformer的综合能源系统多元负荷短期预测[J]. 电力系统保护与控制, 2023, 51(15): 33-41.
LI Yunsong, ZHANG Zhisheng. Multi load short-term forecasting of an integrated energy system based on a GRU-TGTransformer[J]. Power System Protection and Control, 2023, 51(15): 33-41.
- [23] WOŹNIAK M, WIECZOREK M, SIŁKA J. BiLSTM deep neural network model for imbalanced medical data of IoT systems[J]. Future Generation Computer Systems, 2023, 141: 489-499.
- [24] 石宜金, 谭贵生, 赵波, 等. 基于模糊综合评估模型与信息融合的电力变压器状态评估方法[J]. 电力系统保护与控制, 2022, 50(21): 167-176.
SHI Yijin, TAN Guisheng, ZHAO Bo, et al. Condition assessment method for power transformers based on fuzzy comprehensive evaluation and information fusion[J]. Power System Protection and Control, 2022, 50(21): 167-176.
- [25] LIUKAI C, LIN G. Static information, K-neighbor, and self-attention aggregated scheme: a transient stability prediction model with enhanced interpretability[J]. Protection and Control of Modern Power Systems, 2023, 8(1): 81-96.
- [26] 陈飞, 王斌, 周东东, 等. 融合改进符号动态熵和随机配置网络的水电机组轴系故障诊断方法[J]. 水利学报, 2022, 53(9): 1127-1139.
CHEN Fei, WANG Bin, ZHOU Dongdong, et al. A fault diagnosis method for shaft system of hydropower units based on improved symbolic dynamic entropy and stochastic configuration network[J]. Journal of Hydraulic Engineering, 2022, 53(9): 1127-1139.

收稿日期: 2023-11-06; 修回日期: 2024-04-22

作者简介:

胡列豪(1995—), 男, 硕士研究生, 研究方向为人工智能在电力系统中的应用; E-mail: 1042306293@qq.com

巩宇(1981—), 男, 通信作者, 硕士, 教授级高级工程师, 研究方向为人工智能在电力系统中的应用; E-mail: gygy820121@126.com

张勇军(1973—), 男, 博士, 教授, 博士生导师, 主要研究方向为智能电网与能源互联网的规划、运行与控制等。

(编辑 许威)