

基于特征提取和TCMNN的主变压器风机声纹故障诊断

徐智帆, 朱超, 蒋善旗, 周显利

引用本文:

徐智帆, 朱超, 蒋善旗, 等. 基于特征提取和TCMNN的主变压器风机声纹故障诊断[J]. 上海电力大学学报, 2025, 41(6): 551-556,596.

XU Zhifan, ZHU Chao, JIANG Shanqi, et al. The Fault Diagnosis from Transformer Fan Voiceprint Based on TCMNN and Feature Extraction[J]. *Journal of Shanghai University of Electric Power*, 2025, 41(6): 551-556,596.

相似文章推荐 (请使用火狐或IE浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

基于改进果蝇算法优化PNN的变压器故障诊断研究

Transformer Fault Diagnosis Based on Improved FOA Optimized PNN

上海电力大学学报. 2020, 36(4): 395-400 <https://doi.org/10.3969/j.issn.2096-8299.2020.04.014>

基于MODWT和BP神经网络的微电网故障诊断方法

A New Microgrid Fault Diagnosis Method Based on MODWT and BP Neural Network

上海电力大学学报. 2021, 37(1): 57-60,77 <https://doi.org/10.3969/j.issn.2096-8299.2021.01.011>

基于RS-RBF的燃气轮机控制系统传感器故障诊断研究

Research on Sensor Fault Diagnosis of Gas Turbine Control System Based on RS-RBF

上海电力大学学报. 2021, 37(1): 17-22 <https://doi.org/10.3969/j.issn.2096-8299.2021.01.004>

基于BP神经网络及其改进算法的汽轮发电机组故障诊断

Fault Diagnosis of Turbo Generator Unit Based on BP Network and Its Improved Algorithm

上海电力大学学报. 2017, 33(4): 362-366 <https://doi.org/10.3969/j.issn.1006-4729.2017.04.011>

基于改进深度信念网络的燃气轮机故障诊断

Research on Gas Turbine Fault Diagnosis Method Based on Genetic Algorithm Optimization for Deep Belief Network

上海电力大学学报. 2020, 36(2): 123-130 <https://doi.org/10.3969/j.issn.2096-8299.2020.02.005>

DOI: 10.3969/j.issn.2096-8299.2025.06.005

基于特征提取和TCMNN的主变压器风机 声纹故障诊断

徐智帆¹, 朱超², 蒋善旗³, 周显利⁴

(1. 国网厦门供电公司, 福建 厦门 361001; 2. 江西省思极科技有限公司, 江西 南昌 330000;
3. 华能浞池热电有限责任公司, 河南 三门峡 450018; 4. 上海电力大学, 上海 200090)

摘要: 为强化主网设备运检体系智能化, 提升运维人员的故障综合诊断水平, 针对主变压器的风机故障诊断在声纹信号研究方面的不足, 提出了一种基于特征提取和两级小脑神经网络(TCMNN)的主变压器风机声纹故障诊断方法。首先, 采用离散小波变换和主成分分析相结合的方法进行特征提取, 提升了特征提取的效率和准确性。其次, 设计了TCMNN结构用于故障检测和故障类型识别, 有效提高了故障诊断的分类性能。最后, 实验结果表明, 在高斯白噪声环境下, 该方法相较于现有方法具有更高的诊断准确率和更强的鲁棒性。

关键词: 两级小脑神经网络; 声纹识别; 特征提取; 故障诊断

中图分类号: TM407; TM411; TM08 文献标志码: A 文章编号: 2096-8299(2025)06-0551-06

The Fault Diagnosis from Transformer Fan Voiceprint Based on TCMNN and Feature Extraction

XU Zhifan¹, ZHU Chao², JIANG Shanqi³, ZHOU Xianli⁴

(1. State Grid Xiamen Electric Power Supply Company, Xiamen, Fujian 361001, China; 2. Jiangxi Siji Technology Co., Ltd., Nanchang, Jiangxi 330000, China; 3. Huaneng Mianchi Power Station, Sanmenxia, Henan 450018, China; 4. Shanghai University of Electric Power, Shanghai 200090, China)

Abstract: To enhance the intelligentization of power system equipment and augment the fault diagnostic competencies of technical personnel, this paper addresses the research gap in acoustic signal analysis for fault diagnosis of transformer fans. This paper presents a method that the voiceprint recognition of motor based on two-stage cerebellar model neural network (TCMNN) and feature extraction. Firstly, the experimental data of voiceprint is collected from a small fan in main transformer. The methodology proposed in this paper employs discrete wavelet transform and principal component analysis for feature extraction, where the selection of wavelet basis functions and decomposition levels is optimized based on wavelet energy analysis to enhance computational efficiency. Secondly, TCMNN is designed for fault detection and fault type identification, effectively enhancing classification performance. Experimental results demonstrate that the proposed framework achieves superior classification accuracy and enhanced robustness compared to conventional methods under white noise conditions.

收稿日期: 2025-02-23

通信作者简介: 周显利 (1994—), 男, 硕士, 助理工程师。主要研究方向为微电网智能控制和并网等。

E-mail: zxl0280924@163.com.

Key words: two-stage cerebellar model neural network; voiceprint recognition; feature extraction; fault diagnosis

随着社会的发展,尤其是云计算和大模型技术的迅猛发展,对电能产生了迫切需求,变电站的新建和扩建步伐显著加快。变压器作为站内关键电磁能量转换节点之一,其故障预警机制与健康状态评估体系的构建一直是电力工程领域产学研协同创新的重点方向。由于220 kV及以上电压等级的变压器通常在散热器片上装设大量风机,因此为了保障变压器在高负载工况下稳定运行,运检人员必须对风机进行检查与故障诊断。风机的主要故障包括扇叶损坏、轴承损坏、线圈烧毁、控制器故障等。风机的声纹信号中包含大量能够反映其运行状态的有效信息,基于该信号进行故障诊断具有非接触、测量方便、可在线带电监测等优势,因此这种诊断技术具有广阔的应用前景^[1]。

针对基于声纹的故障诊断在电力变压器中的应用,国内外学者和工程师已开展了大量理论及应用研究。文献[2]对短路冲击时的变压器声纹展开分析,探究该暂态声纹与绕组变形之间的关系,为绕组状态分析的前期工作提供了参考。文献[3]围绕本体放电开展基于声纹的故障诊断研究,其中运用小波包进行时频变换,对不同放电现象的判断准确率较高。文献[4]根据物理公式和先验知识对遭遇不同工况或故障的变压器进行分析,并采用迁移网络算法提升了模型的训练效率。文献[5]针对绕组和铁心松动问题,提出对不同频段的信号采用不同的特征提取方式,减少了冗余特征,提升了机器学习效率。由于声纹信号具有复杂性,相关文献的研究对象主要为本体绕组、套管等,较少针对风机、潜油泵等变压器辅助设备进行分析。

近年来,随着硬件设备与数据采集技术的发展,人工智能在电力设备中的应用逐渐成为工程人员研究的重点。文献[6]利用两级人工智能分类算法对储能电机的声纹进行故障诊断,取得了比单级神经网络更高的准确率。文献[7]基于变压器油色谱数据,运用机器学习对变压器故障进行多分类诊断。小脑模型神经网络(Cerebellar Model Neural Network, CMNN)结构特殊,具有多层激发结构和局部更新特性,已在状态识别与故障诊断中获得成功应用^[8]。文献[9]采用遗传算

法对CMNN的超参数进行优化,并采用主成分分析(Principal Component Analysis, PCA)对故障特征进行分析,提升了诊断准确率。文献[10]提出使用多层CMNN叠加进行信号降噪,取得了良好效果。文献[11]采用两级卷积神经网络对心音信号进行诊断,其准确率比普通卷积神经网络更高。此外,两级网络算法较为简单,更有利于在实际临床中部署使用。

本文首先介绍特征提取和两级小脑神经网络(Two-stage CMNN, TCMNN)的原理,并构建一种主变压器风机声纹故障诊断方法;其次,分析声纹信号及风机故障的诊断结果,并进行对比;最后,利用实验室采集的风机声纹信号,验证所提方法对风机故障诊断的准确性。

1 特征提取和TCMNN

1.1 基于离散小波变换和PCA的特征提取

与传统故障诊断中具有规律性正弦或固定频率的信号不同,声纹信号(尤其是故障声纹)通常呈现非规律性且具有突变特性,因此本文采用离散小波变换(Discrete Wavelet Transform, DWT)进行特征提取与处理。基于多分辨率分析的DWT可根据尺度函数和小波函数,对能量有限的任意信号 $f(t)$ 进行处理^[12]。 $f(t)$ 的表达式为

$$f(t) = \sum_{k=0}^{2^N-1} a_{M,k} \phi_{M,k}(t) + \sum_{m=1}^M \sum_{k=0}^{2^N-1} d_{m,k} \psi_{m,k}(t) \quad (1)$$

式中: 2^N ——采样数据的长度, N 为正整数;

m ——分解层数;

k ——近似空间的尺度;

$a_{M,k}$ —— M 层和尺度 k 下的尺度系数;

$\phi_{M,k}(t)$ —— M 层和尺度 k 下的尺度函数;

M ——分解层总数;

$d_{m,k}$ —— m 层和尺度 k 下的小波系数;

$\psi_{m,k}(t)$ —— m 层和尺度 k 下的小波函数。

为平衡输入维数与特征的合理性,通常选择特征能量系数作为神经网络的输入^[13]。特征能量系数的公式为

$$E_a = \sum_{k=1}^{q_a} |a_{M,k}|^2, \quad E_d = \sum_{k=1}^{q_d} |d_{m,k}|^2 \quad (2)$$

式中: E_a ——尺度能量系数;

q_M ——尺度系数在 M 层下的长度;

E_d ——小波能量系数;

q_m ——小波系数在 m 层下的长度。

对同一信号采用不同小波基函数分解的结果存在差异。这是其时频域特性不同所致,而分解层数的差异决定了DWT的计算量。为确保提取的特征信息更丰富且小波能量系数和更集中,本文将小波能量系数和作为小波基函数和分解层数的选择依据。此外,为进一步提高特征分析效率和CMNN的泛化性能,需进行特征选择。PCA可通过去除部分冗余特征实现数据降维,同时具备降噪作用^[14]。对数量较多的高频信号小波能量系数进行降维,并将尺度能量系数 E_a 作为TCMNN的输入,以保障特征提取的有效性和运算效率。

以小波分解10层为例,特征提取方法的结构如图1所示。其中: $a_1 \sim a_{10}$ 表示分解层数为10层时第1~10层的尺度系数; $d_1 \sim d_{10}$ 表示第1~10层的小波系数; $E_1 \sim E_{10}$ 表示第1~10层的小波能量系数, E_{11} 表示第10层的尺度能量系数; $F_1 \sim F_{10}$ 表示 $E_1 \sim E_{10}$ 经过PCA降维后的结果。

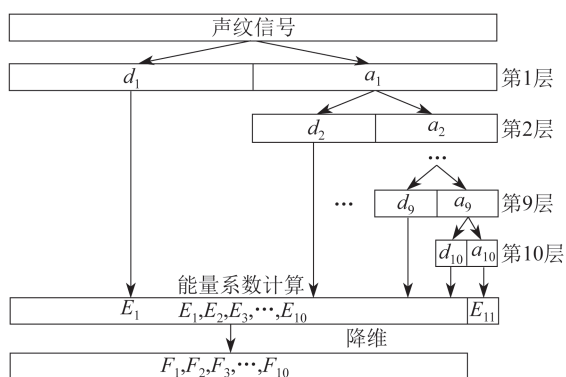


图1 特征提取方法的结构

1.2 TCMNN原理

本文设计的TCMNN由2个二分类的CMNN构成。单级CMNN结构如图2所示。其中: p_i ($i=1, 2, 3, \dots, n_1$)表示输入向量, n_1 为输入层维度; R_b ($b=1, 2, 3, \dots, n_2$)表示接收域层中第 b 个单元的触发强度, n_2 为联想记忆层内设置的层数; w_b 表示权值层内对应的接收域层第 b 个单元的权值。

在输入层中,定义输入向量 p_i 为已知数据。将该向量输入CMNN,并执行前向计算。




图2 单级CMNN结构

在联想记忆层中,单次输入会同时激活不同层的模糊集,对应的接收域高斯基函数公式为

$$\varphi_{i,b,c} = \exp\left(\frac{-(p_i - \chi_{i,b,c})^2}{v_{i,b,c}^2}\right), \quad c=1, 2, 3, \dots, n_3 \quad (3)$$

式中: $\varphi_{i,b,c}$ ——第 i 个输入向量对应第 b 层、第 c 块的高斯基函数;

$\chi_{i,b,c}, v_{i,b,c}$ ——高斯函数的均值和方差;

n_3 ——联想记忆层内每一层包含的块数。

由于CMNN的结构特殊使其不仅具备较好的泛化能力,而且每次更新参数时仅有部分参数参与更新,因此相较于传统的模糊神经网络,CMNN的计算量更小。

在接收域层中,将第2层的输出结果按联想记忆层的各层关系进行累乘,用于计算输入向量对联想单元的触发强度。计算公式如下:

$$R_b = \prod_{i=1}^{n_1} \varphi_{i,b,c} \quad (4)$$

在权值层中,触发强度对应的值向量 w 为

$$w = [w_1, \dots, w_b, \dots, w_{n_2}]^T \quad (5)$$

式中: $w_1 \sim w_{n_2}$ ——权值层内对应的接收域层第 $1 \sim n_2$ 个单元的权值。

在输出层中,由于最后的输出为诊断结果,因此本文采用sigmoid函数直接将输出结果转化为0或1,使得分类过程更加简便。输出结果为

$$o = \sum_{b=1}^{n_2} w_b R_b \quad (6)$$

$$y = \frac{1}{1 + \exp(-o)} \quad (7)$$

式中: o ——CMNN输出层的输出结果;

y ——sigmoid函数的输出结果。

在CMNN的参数优化过程中,采用梯度下降算法对可调权重进行迭代更新,并遵循误差最小化准则。损失函数 E 的公式如下:

$$E = \frac{1}{2} (y_t - y)^2 \quad (8)$$

式中： y_t ——期望输出。

根据链式求导法则，变化量 Δw_b 、 $\Delta \chi_{i,b,c}$ 、 $\Delta v_{i,b,c}$ 的公式分别为

$$\Delta w_b = -\eta_w \frac{\partial E}{\partial w_b} = -\eta_w \frac{\partial E}{\partial y} \frac{\partial y}{\partial o} \frac{\partial o}{\partial w_b} = \eta_w (y_t - y) y (1 - y) R_b \quad (9)$$

$$\Delta \chi_{i,b,c} = -\eta_x \frac{\partial E}{\partial \chi_{i,b,c}} = -\eta_x \frac{\partial E}{\partial y} \frac{\partial y}{\partial o} \frac{\partial o}{\partial R_b} \frac{\partial R_b}{\partial \varphi_{i,b,c}} \frac{\partial \varphi_{i,b,c}}{\partial \chi_{i,b,c}} = \eta_x (y_t - y) y (1 - y) w_b R_b \frac{2(p_i - \chi_{i,b,c})}{v_{i,b,c}^2} \quad (10)$$

$$\Delta v_{i,b,c} = -\eta_v \frac{\partial E}{\partial v_{i,b,c}} = -\eta_v \frac{\partial E}{\partial y} \frac{\partial y}{\partial o} \frac{\partial o}{\partial R_b} \frac{\partial R_b}{\partial \varphi_{i,b,c}} \frac{\partial \varphi_{i,b,c}}{\partial v_{i,b,c}} = \eta_v (y_t - y) y (1 - y) w_b R_b \frac{2(p_i - \chi_{i,b,c})^2}{v_{i,b,c}^3} \quad (11)$$

式中： η_w 、 η_x 、 η_v —— w_b 、 $\chi_{i,b,c}$ 、 $v_{i,b,c}$ 的学习率。

利用TCMNN对特征提取结果进行故障诊断，TCMNN结构如图3所示。其中： y_1 为第1级CMNN的诊断结果； y_2 为第2级CMNN的诊断结果。




图3 TCMNN结构

图3中，第1级CMNN诊断风机是否发生故障，第2级CMNN根据第1级的输出结果确定具体故障类型。本文所提方法有别于文献[9]中采用单个神经网络直接进行多分类输出的故障诊断方式，不仅在一定程度上避免了单个神经网络在多分类中出现参数复杂化和局部最优解的问题，而且可根据实际需求对风机进行故障诊断。

2 实验结果与分析

2.1 实验数据分析与诊断过程

当前35 kV及以上电压等级的变压器通常为油浸式变压器，其外冷却方式主要包括自然风冷、强迫风冷和液冷^[15]。其中，自然风冷通常用于110 kV及以下电压等级且容量较小的变压器，液冷维护成本较高且在长期运行中存在漏液风险，因此当前市级电网变电站内的主变压器大量采用强迫风冷方式保障安全运行。

本文以主变压器上常用的一款散热风机为例，其型号为YJF6130，针对常见的扇叶损坏和轴承损坏两种故障状态下的风机声纹展开分析。采集正常、扇叶损坏和轴承损坏3种工况下风机的声纹信号，并使用杭州爱华AWA6292型声级计采集信号，采样频率为32 kHz。不同工况下的风机声纹如图4所示。




图4 不同工况下的风机声纹

图4中的声纹信号难以直接反映风机是否发生故障或故障类型，因此需进行相应的信号提取与故障诊断。

基于DWT-PCA和TCMNN的故障诊断流程如图5所示。

图5中，在离线训练环节，首先采集训练和测试所需的风机声纹信号；其次，使用DWT-PCA

对1 s内的风机声纹进行特征提取,并将数据分为训练集和测试集;最后,基于TCMNN和训练集更新参数直至收敛,并通过测试集测试以确定其是否满足准确率要求。同理,在线诊断环节中,直接利用训练好的TCMNN模型,对实际声纹信号进行诊断,以确保所提方法的有效性。

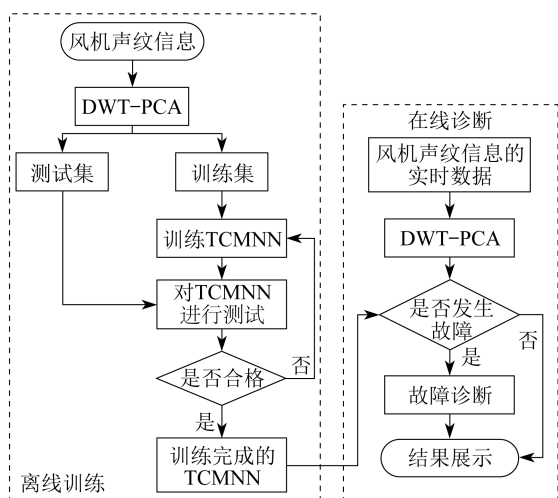


图5 基于DWT-PCA和TCMNN的故障诊断流程

由于小波基函数和分解层数的不同会导致DWT输出的能量系数和尺度系数存在差异,为了使风机声纹信号的小波分解所提取的特征信息更丰富、诊断准确率更高,需选取合适的小波基函数和分解层数。因此,本文采用不同小波基函数和分解层数计算正常工况下风机声纹信号的小波能量系数和,并进行对比。结果表明:Db2小波的小波能量系数和相较于其他小波基函数更大,且其能量系数和达到最大值时的分解层数为10。

风机正常运行时,声纹信号在Db2和Db3小波不同分解层数下的小波能量系数和如图6所示。

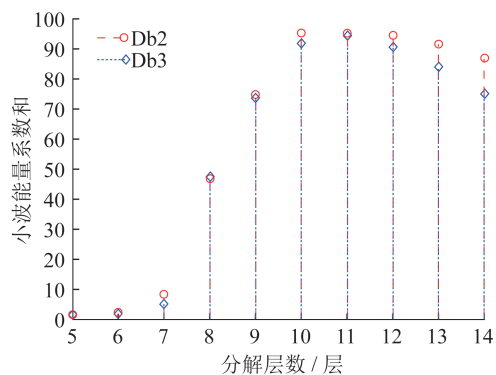


图6 声纹信号在Db2和Db3小波不同分解层数下的小波能量系数和

由图6可以看出,声纹信号在Db2小波分解层数为10层时的小波能量系数和达到最大,且大于在Db3小波分解层数为11层时的小波能量系数和。此时,Db2小波能量系数包含的信息更多且计算量更少。相较于其他小波基函数,Db2小波在特征提取上的性能最优。对声纹信号的小波能量系数进行降维后,根据主成分贡献率筛选输入特征,并将其与尺度能量系数共同作为TCMNN的输入。

2.2 结果对比与分析

基于不同工况下的声纹信号,本文将特征提取后的数据分为训练集、测试集和验证集,数量分别为1 200、300、300组,各数据集均包含正常、扇叶损坏和轴承损坏3种工况下的数据。TCMNN对验证集的诊断结果如图7所示。




图7 TCMNN对验证集的诊断结果

由图7可知,TCMNN对验证集的诊断结果中有3次误判:2次将正常误判为扇叶损坏;1次将轴承损坏误判为扇叶损坏。因此得出,TCMNN的诊断总准确率为99.00%。其中,对风机是否发生故障的诊断准确率为99.33%、召回率为100.00%、F1分数为99.75%,对故障类型的诊断准确率为99.50%。

本文选取CMNN、3层隐藏层的反向传播神经网络(Back Propagation Neural Network, BPNN)和单层的模糊神经网络(Fuzzy Neural Network, FNN)作为对比方法,不同方法的诊断准确率如表1所示。其中,准确率1、召回率和F1分数对应风机是否发生故障的诊断结果,准确率2对应风机故障类型的诊断结果。

表1 不同方法的诊断准确率 单位:%

方法	总准确率	准确率1	召回率	F1分数	准确率2
TCMNN	99.00	99.33	100.00	99.75	99.50
CMNN	97.67	99.33	100.00	99.50	97.50
BPNN	93.33	99.00	100.00	99.25	96.00
FNN	93.67	98.33	99.33	98.92	93.00

由表1可知,TCMNN对验证集的故障诊断总准确率、F1分数和故障类型准确率最高,针对故障是否发生的诊断准确率和召回率与其他方法差距较小。这可能是由于在多分类问题中,当不同故障类型的输入特征较为相似时,二分类单一神经网络性能优于多分类单一神经网络。本文参考故障树的逻辑分类,通过不同神经网络的分工提升整体性能,将风机声纹故障诊断划分为故障是否发生和故障类型两层诊断,使不同逻辑层级的CMNN能针对不同情况更好地完成诊断。

此外,由于实验室声纹采集环境较为理想,而实际工作中难以避免其他噪声干扰。为检验本文所提方法的鲁棒性,对训练集和验证集分别添加40、50 dB 高斯白噪声(实验1工况),以及对训练集和验证集均添加50 dB 高斯白噪声(实验2工

况)。TCMNN在实验1工况下的诊断结果如图8所示。




图8 TCMNN在实验1工况下的诊断结果

由图8可知,在训练集和验证集分别添加40、50 dB 高斯白噪声的工况下,TCMNN的诊断总准确率为92.33%,对风机是否发生故障的诊断准确率为96.67%,对故障类型的诊断准确率为91.50%。误判主要出现在故障类型的诊断中,这可能是由于不同类型故障的特征提取结果存在一定程度的相似性,导致噪声干扰后诊断准确率明显下降。

含噪声工况下的诊断准确率对比如表2所示。

表2 含噪声工况下的诊断准确率对比

单位:%

方法	实验1				实验2			
	总准确率	准确率1	召回率	准确率2	总准确率	准确率1	召回率	准确率2
TCMNN	92.33	96.67	98.00	91.50	92.67	96.67	98.00	92.00
CMNN	90.00	96.00	97.00	88.00	90.67	96.33	97.50	89.00
BPNN	89.00	95.33	97.00	87.50	90.33	95.67	96.50	88.50
FNN	85.67	94.33	96.00	83.00	86.67	94.67	96.00	84.00

由表2可知,在不同噪声干扰下,TCMNN的各项准确率和召回率均最高,且与表1数据相比下降幅度较小。这可能是由于小波分解对干扰信号的处理效果、TCMNN的特殊逻辑在分类器上的优势,以及正常与故障的风机声纹特征差异较大,同时本文所使用的特征提取方法和TCMNN具有一定的鲁棒性,因此噪声干扰后的诊断准确率仍较高。

3 结 语

本文提出了一种基于特征提取和TCMNN的风机声纹故障诊断方法。其中,特征提取方法去除了大量冗余信息,降低了神经网络输入复杂度;

TCMNN的实验结果验证了所提方法的有效性。因此,后续可依托设备本体采集特征信号进行边缘计算,以实现一定的工程价值;发现问题时可立即停止风机运行并检查,提升运维人员的设备维护能力,提升基层作业班组的智能化和全能化水平。

然而,本文所使用的特征提取方法仍有优化空间。后续研究可进一步分析多物理场干扰下不同故障声纹信号与机械振动的关系,以故障机理驱动提升特征提取有效性,减少对神经网络泛化能力的依赖。此外,还可以考虑针对不同领域的波形或图像特征进行分析,以验证所提方法的适用性。

(下转第596页)

- metal-based phosphides in energy-related electrocatalysis [J]. *Advanced Energy Materials*, 2020, 10(11): 1902104.
- [21] QI R W, BU H K, YANG X, et al. Multifunctional molybdenum-tuning porous nickel-cobalt bimetallic phosphide nanoarrays for efficient water splitting and energy-saving hydrogen production [J]. *Journal of Colloid and Interface Science*, 2024, 653: 1246-1255.
- [22] SAWHILL S J, LAYMAN K A, VAN WYK D R, et al. Thiophene hydrodesulfurization over nickel phosphide catalysts: effect of the precursor composition and support [J]. *Journal of Catalysis*, 2005, 231(2): 300-313.
- [23] KORÁNYI T I. Phosphorus promotion of Ni (Co) -containing Mo-free catalysts in thiophene hydrodesulfurization [J]. *Applied Catalysis A: General*, 2003, 239(1): 253-267.
- [24] YU B, WANG X Q, QI F, et al. Self-assembled coral-like hierarchical architecture constructed by NiSe₂ nanocrystals with comparable hydrogen-evolution performance of precious platinum catalyst [J]. *ACS Applied Materials & Interfaces*, 2017, 9(8): 7154-7159.
- [25] TANG C, PU Z H, LIU Q, et al. In situ growth of NiSe nanowire film on nickel foam as an electrode for high-performance supercapacitors [J]. *Chem Electro Chem*, 2015, 2(12): 1903-1907.
- [26] ZHU K Y, ZHU X F, YANG W S. Application of in situ techniques for the characterization of NiFe-based oxygen evolution reaction (OER) electrocatalysts [J]. *Angewandte Chemie International Edition*, 2019, 58(5): 1252-1265.
- [27] ZHANG N, HU Y, AN L, et al. Surface activation and Ni-S stabilization in NiO/NiS₂ for efficient oxygen evolution reaction [J]. *Angewandte Chemie*, 2022, 134(35): e202207217.

(责任编辑 桂金星)

(上接第 556 页)

参考文献:

- [1] 刘云鹏, 来庭煜, 刘嘉硕, 等. 特高压直流换流阀饱和电抗器振动声纹特性与松动程度声纹检测方法[J]. *电工技术学报*, 2023, 38(5): 1375-1389.
- [2] 刘云鹏, 王博闻, 李欢, 等. 结合载纤绕组形变测量法的大型变压器绕组多次短路冲击暂态声纹特征[J]. *中国电机工程学报*, 2022, 42(1): 434-447.
- [3] 吴国鑫, 詹花茂, 李敏. 声纹的变压器放电与机械故障诊断研究[J]. *应用声学*, 2021, 40(4): 602-610.
- [4] 齐子豪, 全杰, 张中浩, 等. 基于多粒度知识特征和Transformer网络的电力变压器故障声纹辨识方法[J]. *中国电机工程学报*, 2025, 45(4): 1311-1323.
- [5] 李楠, 马宏忠, 朱昊, 等. 基于 50 Hz 倍频小波时频熵和RUSBoost的变压器绕组松动声纹识别[J]. *电机与控制应用*, 2022, 49(5): 87-93.
- [6] 孙汉文, 李喆, 林睿, 等. 基于新奇检测的两级电气故障声纹识别算法[J]. *电网技术*, 2021, 45(7): 2888-2895.
- [7] 廖才波, 杨金鑫, 胡雄, 等. 数据与经验混合驱动下的变压器故障分层诊断方法[J]. *高电压技术*, 2023, 49(5): 1841-1850.
- [8] 徐智帆, 李华森, 李文院, 等. 基于递归小脑模型神经网络和卡尔曼滤波器的锂电池荷电状态预测[J]. *综合智慧能源*, 2024, 46(7): 81-86.
- [9] LIN Q, CHEN S, LIN C M. An optimization method for the initial parameters selection of fuzzy cerebellar model neural networks in parametric fault diagnosis [J]. *International Journal of Fuzzy Systems*, 2022, 22: 2071-2082.
- [10] TSA Y, CHU H C, FANG S H, et al. Adaptive noise cancellation using deep cerebellar model articulation controller [J]. *IEEE Access*, 2018, 6: 37395-37402.
- [11] 冯正伟, 全海燕. 基于两级神经网络的心音分割[J]. *数据采集与处理*, 2023, 38(4): 849-859.
- [12] NING J, WANG J, GAO W, et al. A wavelet-based data compression technique for smart grid [J]. *IEEE Transactions on Smart Grid*, 2011, 2(1): 212-218.
- [13] LIN Q, XU Z, LIN C M. Battery-supercapacitor state-of-health estimation for hybrid energy storage system using a fuzzy brain emotional learning neural network [J]. *International Journal of Fuzzy Systems*, 2022, 24(1): 12-26.
- [14] LI H, LINDERMAN G C, SZLAM A, et al. Algorithm 971: an implementation of a randomized algorithm for principal component analysis [J]. *ACM Transactions on Mathematical Software (TOMS)*, 2017, 43(3): 1-14.
- [15] 杨忠原, 张杰, 饶兴宁, 等. 大型变压器散热技术发展现状及展望[J]. *能源研究与管理*, 2024, 16(3): 41-48.

(责任编辑 白林雪)