

DOI: 10.13382/j.jemi.B2508097

# 结合多尺度熵的 SVMD-CPO-RF-AdaBoost 均压电极结垢智能识别方法\*

闫孝姮<sup>1</sup> 王治仁<sup>1</sup> 赵一澄<sup>2</sup> 陈伟华<sup>1</sup> 张维广<sup>1</sup>

(1. 辽宁工程技术大学电气与控制工程学院 葫芦岛 125105; 2. 国网辽宁省电力有限公司辽阳供电公司 辽阳 111000)

**摘要:**针对现有均压电极结垢超声回波检测法中结垢厚度识别不精确的问题,提出了一种结合多尺度熵的逐次变分模态分解法(SVMD)-冠豪猪算法(CPO)-随机森林(RF)-AdaBoost均压电极结垢智能识别方法。采用SVMD对超声回波信号进行分解,并根据模态选取方法筛选出有效信号成分进行重构,实现信号降噪;引入多尺度排列熵(MPE)和多尺度散布熵(MDE)作为特征提取方法,提取不同结垢厚度的均压电极超声回波信号的多尺度特征;将RF作为AdaBoost的弱分类器,构建RF-AdaBoost双集成学习模型,并通过CPO对模型参数进行优化,以实现结垢厚度的智能识别;开展了不同多尺度熵以及CPO-RF、CPO-AdaBoost、CPO-SVM等6种模型的对比研究。实验结果表明,结合MPE与MDE特征的结垢厚度识别准确率优于单一特征;所提方法能够准确识别0~0.8 mm范围内的均压电极结垢厚度,识别准确率达到了94.50%,且精确率、召回率和F1值均优于其他方法,为特高压换流站均压电极结垢提供了一种智能识别方法。

**关键词:**均压电极结垢;智能识别;多尺度特征;双集成学习;冠豪猪算法

**中图分类号:** TN06; TM772

**文献标识码:** A

**国家标准学科分类代码:** 470.40

## Intelligent identification method of grading electrodes sediments based on SVMD-CPO-RF-AdaBoost combining multiscale entropies

Yan Xiaoheng<sup>1</sup> Wang Zhiren<sup>1</sup> Zhao Yicheng<sup>2</sup> Chen Weihua<sup>1</sup> Zhang Weiguang<sup>1</sup>

(1. Faculty of Electrical and Control Engineering, Liaoning Technical University, Huludao 125105, China;

2. Liaoyang Power Supply Company of State Grid Liaoning Province Electric Power Co., Ltd., Liaoyang 111000, China)

**Abstract:** To address the issue of inaccurate sediment thickness identification in the existing ultrasonic echo detection method for grading electrodes sediments, an intelligent identification method of grading electrodes sediments based on SVMD-CPO-RF-AdaBoost combining multiscale entropies is proposed. The successive variational mode decomposition method is used to decompose the ultrasonic echo signals, and effective signal components are selected and reconstructed based on the modal selection method to achieve signal denoising. Multiscale permutation entropy and multiscale dispersion entropy are introduced as feature extraction methods to extract the multiscale features of ultrasonic echo signals from grading electrodes with different sediments thicknesses. A dual ensemble learning model of RF-AdaBoost, with random forest as the weak classifier of AdaBoost, is constructed and optimized by the crested porcupine optimizer to achieve intelligent identification of sediment thicknesses. A comparative study was conducted on different multiscale entropies, as well as six models including CPO-RF, CPO-AdaBoost, and CPO-SVM. Experimental results show that the recognition accuracy of sediment thicknesses using a combination of MPE and MDE features is superior to that using a single feature. The proposed method can accurately identify the sediment thickness of the grading electrodes sediments in the range of 0 to 0.8 mm, with a recognition accuracy of 94.50%. Moreover, its precision, recall, and F1 score outperform those of other methods, providing an intelligent identification solution for grading electrodes sediments in ultra-high voltage converter stations.

**Keywords:** grading electrodes sediments; intelligent identification; multiscale features; dual ensemble learning; crested porcupine optimizer

## 0 引言

均压电极是减缓特高压换流站换流阀冷却系统中金属散热器腐蚀的关键装置<sup>[1]</sup>。在长期运行过程中,金属散热器腐蚀所产生的带电离子,在电场作用下游离至均压电极表面形成垢层,当结垢层达到一定厚度,会加剧散热器腐蚀程度,造成换流阀冷却系统故障<sup>[2]</sup>。当前均压电极结垢检测主要采取人工逐个筛检法,此法易因操作不当导致冷却水淋湿大功率电力电子器件,诱发次生事故,造成重大经济损失<sup>[3]</sup>。

目前,一些学者将超声波检测法应用于均压电极结垢检测之中,实现非侵入性检测,解决了传统检测方法的弊端。闫孝娟等<sup>[4]</sup>率先提出基于 L(0,2) 超声导波特性的在线结垢检测技术,实现了结垢厚度 0.1 mm 级别的检测精度。次年,陈伟华等<sup>[5]</sup>首次采用超声回波法采集均压电极结垢信号,提出了一种基于 RWSSA-OMP-DBN 结垢识别方法,该方法识别准确率为 87.56%,但对 0.3 mm 以下的垢层厚度识别效果较差。随后,Chen 等<sup>[6]</sup>进一步提出了一种基于时频域混合熵的均压电极结垢检测方法,解决了不同结垢厚度超声回波信号特征差异性弱的问题,能够识别 0.1~0.8 mm 的均压电极结垢厚度,达到了 94.25% 的准确率。刘骁眸等<sup>[7]</sup>提出了一种基于互补集合经验模态分解 (CEEMD) 和改进天牛须算法 (IBAS)-支持向量机 (SVM) 的均压电极结垢识别方法,该方法对 0.3、0.5 和 0.8 mm 结垢厚度的均压电极识别效果较差。

以上方法在均压电极结垢检测方面已经取得了一定成效,但对结垢厚度识别模型只是单一模型,这种情况容易导致模型的泛化能力不足、稳定性差,且对部分结垢厚度识别效果不精确。集成学习模型能够通过集成多个模型来解决单一模型的缺陷<sup>[8-9]</sup>。集成学习模型主要包括随机森林 (random forest, RF)<sup>[10]</sup>、Stacking<sup>[11]</sup>、AdaBoost<sup>[12]</sup>、GBDT<sup>[13]</sup>、XGBoost<sup>[14]</sup>、CatBoost<sup>[15]</sup> 等。其中,AdaBoost 能够自适应调整权重,具有精度高、灵活性强等特点。通常采用决策树作为 AdaBoost 的弱分类器,由于其结构简单,无法充分利用 AdaBoost 的扩展潜力,若将其其它的集成学习模型代替决策树作为弱分类器,则可以很好的解决这一问题。谢国民等<sup>[16]</sup>将混合核极限学习机作为 AdaBoost 弱分类器用于变压器故障诊断,该模型的准确率达到 96%。郑伟宏等<sup>[17]</sup>提出了一种基于 AdaBoost-GBDT 的短期风力电功率预测模型,相较于单集成学习模型,双集成学习模型预测精度更高。Yun 等<sup>[18]</sup>提出了一种基于增量式宽泛学习策略改进的 AdaBoost-Stacking 模型,通过实验证明,所提模型的适应性和精确度明显优于其他先进模型。

双集成学习模型可以有效地结合两个单集成学习模

型的互补信息,提高集成模型的鲁棒性,增加识别的准确率。本文提出一种结合多尺度熵的逐次变分模态分解 (SVMD)-冠豪猪算法 (CPO)-RF-AdaBoost 均压电极结垢智能识别方法。采用 SVMD 将超声回波信号分解成不同模态的子信号,根据模态选取方法重构有效模态,去除信号中的高低频噪声;选用多尺度排列熵 (multiscale permutation entropy, MPE) 和多尺度散布熵 (multiscale dispersion entropy, MDE) 作为特征提取方法,提取不同结垢厚度的均压电极超声回波信号的特征信息;将 RF 作为 AdaBoost 算法弱分类器,构建成 RF-AdaBoost 双集成学习模型,并采用 CPO 算法对模型参数进行寻优,用于均压电极结垢识别。

## 1 均压电极结垢超声回波检测法原理

超声回波检测法基于超声波在不同介质中的反射特性,当超声波以垂直方向传播到声阻抗不同的介质时,由于阻抗不匹配,部分声波会在交界处发生反射,形成反射回波,其反射强度可通过声压反射率进行量化,公式如下:

$$R = \frac{p_r}{p_o} = \frac{Z_2 - Z_1}{Z_2 + Z_1} \quad (1)$$

式中:  $p_o$  和  $p_r$  为入射波和反射波的声压;  $Z_1$  和  $Z_2$  为不同介质的声阻抗。均压电极结垢超声回波检测法原理如图 1(a) 所示,超声探头向均压电极垂直发射超声波,超声波在穿过管道壁、去离子水和均压电极时,因声阻抗差异,会在前管道壁、均压电极处和后管道壁发生反射,超声探头接收到的回波信号会在时域图像中呈现出反射波的时刻和强度变化,如图 1(b) 所示。

当均压电极表面无结垢时,均压电极处首个出现的反射回波来自去离子水与电极界面的反射,在时域图像中出现时间可表示为:

$$t_{s_2} = 2 \left( \frac{d_1}{v_1} + \frac{d_2}{v_2} \right) \quad (2)$$

式中:  $d_1$  为管壁厚度;  $d_2$  为管壁到均压电极表面距离;  $v_1$  和  $v_2$  分别为管壁声速和去离子水声速。当均压电极表面形成结垢层时,结垢层与均压电极、去离子水同样存在声阻抗差异,且结垢层为多孔隙垢层<sup>[19]</sup>,超声波会在均压电极处发生多次反射。在这种情况下,均压电极处首先出现的反射回波主要来自去离子水与结垢层之间的界面,出现时间变为:

$$t_{s_2} = 2 \left( \frac{d_1}{v_1} + \frac{d_2 - \Delta d}{v_2} \right) \quad (3)$$

式中:  $\Delta d$  为结垢厚度,当结垢厚度增加时,会缩短超声波在去离子水中的传播距离,使反射回波到达时间提前。结垢厚度还会影响超声回波信号的强度,超声波在结垢




图 1 超声回波检测法原理与波形

Fig. 1 Schematic diagram and waveform diagram of ultrasonic echo detection method

层内传播时,会经历吸收、反射等过程,导致能量逐渐损耗,进而使回波信号的强度发生衰减。

通过分析超声回波信号的时间和强度变化,可以推断出均压电极的结垢厚度。但在实际工况中,均压电极结垢厚度通常处于亚毫米级,导致结垢与未结垢之间的超声回波信号时间偏移量极小,信号强度变化不显著,尤其在相邻厚度之间。此外,环境噪声干扰会进一步掩盖超声回波信号特征的可辨识度,工作人员难以通过肉眼直接识别结垢厚度。因此,需要对超声回波信号进一步

分析处理,以提高均压电极结垢厚度检测的准确性和可靠性。

## 2 SVM-D-CPO-RF-AdaBoost 模型

基于均压电极结垢超声回波检测法的应用需求,结合多尺度熵的 SVM-D-CPO-RF-AdaBoost 模型结构如图 2 所示,主要由信号降噪、特征提取和结垢识别 3 部分组成。

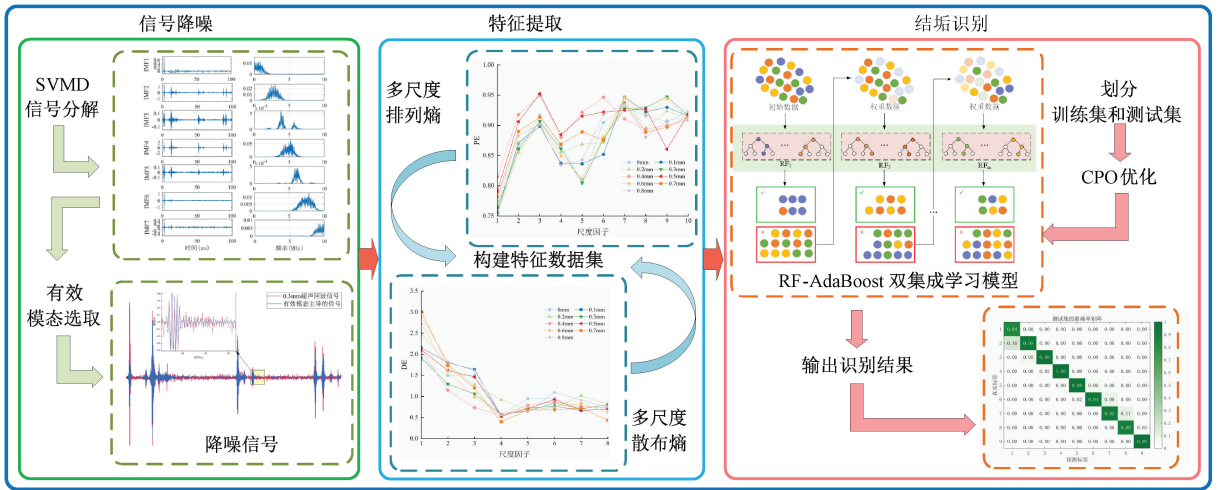


图 2 结合多尺度熵的 SVM-D-CPO-RF-AdaBoost 模型结构

Fig. 2 Model architecture diagram of SVM-D-CPO-RF-AdaBoost combined with MPE

### 2.1 SVM 与模态选取方法

采用 SVM 法将超声回波信号分解为不同模态的子信号,依据模态选取方法筛选出由有效模态主导的信号分量进行重构,将重构信号作为降噪后的信号。

SVM 是在变分模态分解 (variational mode decomposition, VMD) 的基础上引入新的约束条件,通过

逐步优化的方式自动确定模态的数量  $k$  值<sup>[20]</sup>。假设超声回波信号  $g(t)$  通过 SVM 分解为第  $k$  个模态  $u_k(t)$  和残差信号  $g_r(t)$  两个信号,如下:

$$g(t) = u_k(t) + g_r(t) \tag{4}$$

式中:残差信号  $g_r(t)$  为已提取模态和未处理信号  $g_u(t)$  之和。

$$g_r(t) = \sum_{i=1}^{k-1} u_i(t) + g_u(t) \quad (5)$$

式中:  $u_i(t)$  为第  $i$  个模态。

引入 3 个约束准则,当提取出  $k - 1$  个模态后提取第  $k$  个时,要保证第  $k$  个模态和信号的未处理部分完全重构的前提是使其最小化,其约束公式为:

$$\begin{cases} \min \{ \alpha A_1 + A_2 + A_3 \} \\ \text{s. t. } u_k(t) + g_r(t) = g(t) \end{cases} \quad (6)$$

式中:  $A_1, A_2, A_3$  为约束准则;  $\alpha$  为惩罚因子,用于平衡约束条件参数。

选用相关系数法进行信号有效模态的选取,其计算公式如下:

$$r = \frac{\sum_{k=1}^n (u_k - \bar{u}_k) (g - \bar{g})}{\sqrt{\sum_{k=1}^n (u_k - \bar{u}_k)^2} \sqrt{\sum_{k=1}^n (g - \bar{g})^2}} \quad (7)$$

式中:  $g$  为原始信号的采样值;  $\bar{g}$  为原始信号的均值;  $u_k$  和  $\bar{u}_k$  为第  $k$  个模态分量的采样值及均值;  $n$  为信号的采样点数。

设定当相关系数满足  $0.5 < r < 1$  时为有效模态主导的信号分量,  $0 < r < 0.5$  时为噪声模态主导的信号分量。

### 2.2 多尺度熵特征提取

多尺度熵是衡量时间序列复杂程度的方法,可在不同尺度下揭示时间序列的动态特性<sup>[21-22]</sup>。随着均压电极结垢厚度的增加,超声回波信号的复杂程度也会发生改变。从多尺度熵的不同特性出发,选用多尺度排列熵和多尺度散布熵作为均压电极超声回波信号的特征提取方法。

多尺度排列熵能够根据数据点的排列模式来评估时间序列的复杂性,其计算流程如图 3 所示。




图 3 多尺度排列熵计算流程  
Fig. 3 MPE calculation flowchart

排列熵的计算公式为:

$$H_{PE} = \frac{- \sum_{r=1}^k P_r \ln P_r}{\ln(m!)} \quad (8)$$

式中:  $P_r$  为序列重构向量相对出现的概率;  $m$  为嵌入维度。在排列熵的基础上引入尺度因子  $s$ ,将时间序列进行粗粒化处理,构造出粗粒化序列,如下:

$$Y_j^{(s)} = \frac{1}{s} \sum_{i=(j-1)s+1}^{js} x_i, 1 \leq j \leq \frac{N}{s} \quad (9)$$

计算每个尺度因子粗粒化序列的排列熵,从而求解新序列的 MPE,其公式为:

$$H_{MPE} = [H_{PE1}, H_{PE2}, \dots, H_{PEs}] \quad (10)$$

多尺度散布熵是将时间序列映射到不同的散布模式中,根据不同散布模式出现的概率来评估时间序列的复杂性。散布熵的计算公式如下:

$$H_{DE} = - \sum_{r=1}^m P(r_{v_0, v_1, \dots, v_{m-1}}) \ln(P(r_{v_0, v_1, \dots, v_{m-1}})) \quad (11)$$

式中:  $P(r_{v_0, v_1, \dots, v_{m-1}})$  为每种散布模式出现的概率。对时间序列进行粗粒化处理,得到相应的粗粒化序列为:

$$W_j^{(s)} = \frac{1}{s} \sum_{i=(j-1)s+1}^{js} x_i, 1 \leq j \leq \frac{N}{s} \quad (12)$$

计算每个尺度因子粗粒化序列的散布熵, MDE 计算公式为:

$$H_{MDE} = [H_{DE1}, H_{DE2}, \dots, H_{DEs}] \quad (13)$$

### 2.3 CPO-RF-AdaBoost 双集成学习模型

AdaBoost 算法是一种具有自适应能力的集成学习算法<sup>[23]</sup>。通常情况下,使用决策树作为 AdaBoost 算法弱分类器,但由于决策树结构简单,无法充分利用 AdaBoost 算法的扩展潜力,而随机森林作为弱分类器可以通过 AdaBoost 集成策略对多个随机森林的决策树分类结果进行二次集成。随机森林属于 Bagging 框架,AdaBoost 属于 Boosting 框架,使两种集成学习协同工作,实现时间长度和可扩展性的优势互补,从而充分发挥随机森林和 AdaBoost 两种学习模型的最大效果。因此,选用随机森林作为 AdaBoost 弱分类器,提出一种 RF-AdaBoost 双集成学习模型,其结构如图 4 所示。




图 4 RF-AdaBoost 双集成学习模型  
Fig. 4 RF-AdaBoost dual ensemble learning model

在 RF-AdaBoost 双集成学习模型中,随机森林的决策树数量和叶子节点数量直接关系到模型的复杂度和泛

化能力。选用 CPO 算法<sup>[24]</sup> 优化决策树数量和叶子节点数量。将未训练的 RF-AdaBoost 模型分类结果与实际类别之间的分类误差作为 CPO 优化算法的适应度函数。CPO-RF-AdaBoost 模型流程如图 5 所示,具体步骤如下:

- 1) 输入初始数据,创建 RF-AdaBoost 模型。
- 2) 设置 CPO 算法最大迭代次数、种群大小、参数变量上限和下限。
- 3) 计算每个冠豪猪个体的适应度函数值。
- 4) 应用循环种群减少技术,动态调整种群大小。
- 5) 执行 4 种不同的防御策略,计算当前所有冠豪猪个体计算适应度值,并更新种群最优适应度的值。
- 6) 当达到预设的最大迭代次数时,输出最优参数。

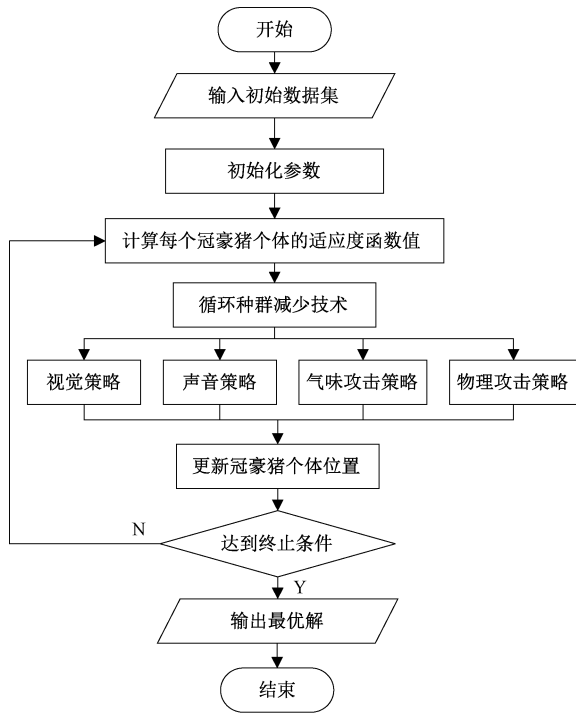


图 5 CPO-RF-AdaBoost 模型流程

Fig. 5 CPO-RF-AdaBoost model flowchart

### 3 实验研究

#### 3.1 实验系统搭建与数据采集

参照换流站中换流阀冷却系统结构,搭建均压电极结垢超声检测实验系统,如图 6 所示,主要由换流阀水冷却系统模拟装置、D790-SM 5 MHz 超声换能器、DPR300 超声脉冲发射接收器、DXO1204A 数字示波器和 PC 构成。

由于在实际工程应用中均压电极结垢过程缓慢,直接获取具有不同结垢厚度的样本较为困难。为检测不同结垢厚度的均压电极,采用模拟自然结垢过程中的主要物质,制备了不同厚度结垢层的均压电极,结垢层厚度从 0~0.8 mm 以每 0.1 mm 递增,如图 7 所示。




图 6 均压电极结垢超声检测系统

Fig. 6 Grading electrodes sediments ultrasonic detection system



图 7 不同结垢厚度的均压电极样本

Fig. 7 Grading electrodes with different sediments thicknesses

分别对 9 种结垢厚度的均压电极进行 230 次超声回波信号采集,为了保证数据质量,去除采集失误、信号丢失等异常信号,每种结垢厚度的均压电极超声回波信号数量精简至 200 个,一共获得 1 800 个有效信号。图 8 所示为 9 种结垢厚度的均压电极超声回波信号,其中  $S_0$  处为超声脉冲初始波形,  $S_1$  处为管壁-流体界面超声反射回波信号,  $S_2$  处为均压电极超声反射回波信号,  $S_3$  处为流体-管壁界面超声反射回波信号。不同结垢厚度的超声回波信号在  $S_0$ 、 $S_1$ 、 $S_3$  处出现时间相对一致,但信号的强度有所不同,结垢层的存在加剧了回波信号的衰减速率,导致在同一时间内反射回波的强度减弱,在  $S_3$  处的衰减现象最为明显,随着均压电极结垢厚度的增加,  $S_2$  处的反射回波出现时间提前,这与理论分析一致。但是相邻结垢厚度之间存在回波重叠现象,尤其是在结垢层厚度较薄时,并且采集到的信号都不可避免的含有噪声,这些因素都使不同结垢厚度的超声回波信号区分变得更加困难。

#### 3.2 信号降噪与特征提取

设置 SVM-D 的惩罚因子  $\alpha = 218$ ,将采集到的 1 800 个不同结垢厚度的均压电极超声回波信号进行 SVM-D 处理。以 0.3 mm 结垢厚度的超声回波信号为例,其各模态分量时频域图如图 9 所示。可以看出,信号被分解为 7




图 8 不同结垢厚度的均压电极超声回波信号

Fig. 8 Ultrasonic echo signals of grading electrodes

个模式分量,其中 IMF1、IMF6 和 IMF7 为噪声模式主导的信号分量,而 IMF2~IMF5 中包含了较多的有效信息。

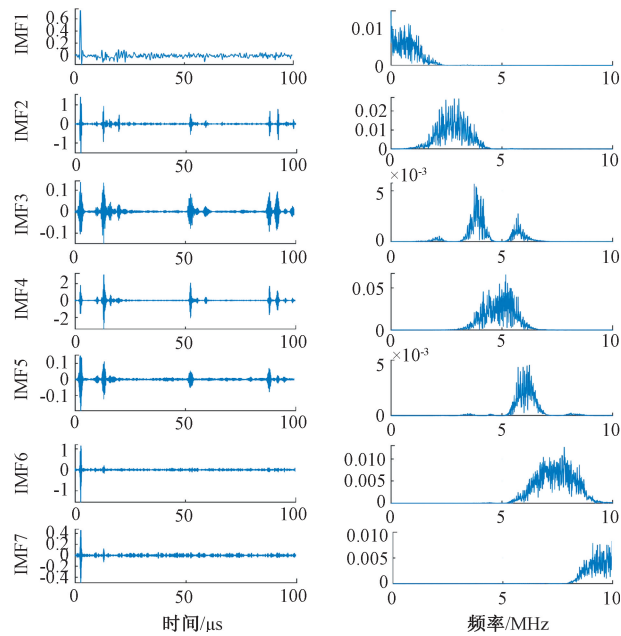


图 9 各模式分量时频域图


Fig. 9 Time-frequency domain diagrams of each mode component

表 1 为各模式分量的相关系数,根据模式选取方法,筛选出有效模式主导的信号分量进行重构,以实现降噪处理。图 10 所示为 0.3 mm 超声回波信号降噪前后的时域图和语谱图,通过比较均压电极超声反射回波处的局部放大信号,未进行降噪前的原始信号受噪声污染,降噪处理后的信号降噪效果明显,保留了原始信号的特征。通常,超声探头的有效信号带宽为其中心频率的 30%~70%,中心频率为 5 MHz 超声探头的有效频率范围大致为 3.5~6.5 MHz。降噪后的信号在语谱图上显示出更为集中的频率分布,并且其频率范围符合超声探头的有效频率范围,信号中的高频和低频噪声被有效抑制,主要的频率成分得到保留,保证了信号的完整性。

表 1 各模式分量的相关系数

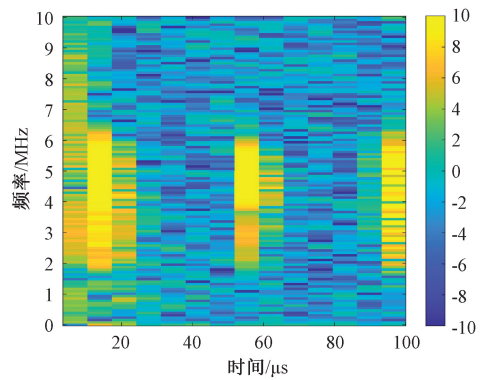
Table 1 Correlation coefficients of each mode component

模式分量	相关系数
IMF1	0.202 4
IMF2	0.489 0
IMF3	0.544 4
IMF4	0.853 5
IMF5	0.347 8
IMF6	0.301 8
IMF7	0.152 6




(a) 降噪前后时域图

(a) Time-domain plot before and after denoising



(b) 降噪前语谱图

(b) Spectrogram before denoising




(c) 降噪后语谱图

(c) Spectrogram after denoising


图 10 0.3 mm 超声回波信号降噪前后的时域图和语谱图

Fig. 10 Time-domain and spectrogram plots of the 0.3 mm ultrasonic echo signal before and after denoising

在对降噪后的超声回波信号进行不同结垢厚度识别之前,需进行特征信息提取。设置 MPE 的参数如下:嵌入维度  $m = 5$ 、延迟时间  $t = 2$ 、时间序列长度  $N = 2\ 000$ 、尺度因子  $s = 10$ ;MDE 参数如下:延迟时间  $t = 2$ 、嵌入维度  $m = 5$ 、时间序列长度  $N = 2\ 000$ 、类别个数  $c = 5$ 、尺度因子  $s = 8$ ,依次对 1 800 个信号进行特征提取。从每种结垢厚度的特征提取结果中随机抽取一组,如图 11 所示。



(a) 多尺度排列熵  
(a) MPE



(b) 多尺度散布熵  
(b) MDE

图 11 特征提取结果

Fig. 11 Feature extraction results

### 3.3 均压电极结垢识别实验

将 0.0~0.8 mm 结垢厚度的 9 种均压电极设置类别标签为 1、2、3、4、5、6、7、8、9,构建 MPE 加标签、MDE 加标签、MPE 与 MDE 加标签共 3 组数据集,用于均压电极结垢识别实验。设置 CPO 算法最大迭代次数 100、种群大小 20、参数变量上限 [300,30]、参数变量下限 [1,1],CPO-RF-AdaBoost 模型的弱分类器个数为 10,并分别对 3 组实验数据集进行随机化处理,按照 80%与 20%的比例,将数据集划分为训练集和测试集,输入到 CPO-RF-AdaBoost 模型进行训练和识别。3 组数据集对应测试集的识别分布和混淆矩阵如图 12 所示。

在测试集单次识别结果中,单独使用 MPE 特征向量的识别准确率为 89.44%,单独使用 MDE 特征向量的识别准确率为 90.56%,结合 MPE 与 MDE 特征向量的识别准确率为 93.89%。由于单次识别结果具有偶然性,为了提高结果的可靠性,对每组数据集进行 10 次重复识别实验,并计算这 10 次实验测试集识别准确率的平均值,以此作为最终识别准确率,识别结果及平均识别准确率如表 2 所示。

表 2 10 次实验识别结果及平均识别准确率

Table 2 Recognition results of 10 experiments and average recognition accuracy (%)

实验次数	MPE	MDE	MPE 和 MDE
第 1 次	89.44	90.56	93.89
第 2 次	89.72	91.35	94.72
第 3 次	90.44	91.91	96.11
第 4 次	91.94	90.83	93.89
第 5 次	92.78	89.14	93.61
第 6 次	88.01	93.06	94.33
第 7 次	91.39	89.44	95.43
第 8 次	90.83	91.67	94.16
第 9 次	89.94	92.22	93.07
第 10 次	91.41	90.72	95.79
平均值	90.59	91.09	94.50

由表 2 可知,将 MPE 和 MDE 结合使用,其识别效果显著优于单独使用任一特征向量,平均识别准确率为 94.50%,分别比单独使用 MPE 高出 3.91%,比单独使用 MDE 高出 3.14%。这是因为,超声回波信号经过 SVMD 降噪后,特征更为突出,且 MPE 和 MDE 能够从不同维度揭示信号的多尺度特性,为 CPO-RF-AdaBoost 模型提供了更为丰富的特征支持,进一步增强了模型的识别能力。

### 3.4 对比实验分析

为证明 CPO-RF-AdaBoost 模型具有良好的识别性能,分别训练了 CPO-RF、CPO-AdaBoost、CPO-SVM、CPO-LSSVM、HO-RF-AdaBoost 和 KOA-RF-AdaBoost 6 种模型进行对比分析。6 种模型的优化算法参数设置如表 3 所示。

表 3 6 种模型的优化算法参数设置

Table 3 Parameter settings for optimization algorithms of six models

模型	种群	迭代次数	变量上限	变量下限
CPO-RF	20	100	300,30	1,1
CPO-AdaBoost	20	100	30	1
CPO-SVM	20	100	100,10	0.1,0.001
CPO-LSSVM	20	100	100,10	1,1
HO-RF-AdaBoost	20	100	300,30	1,1
KOA-RF-AdaBoost	20	100	300,30	1,1

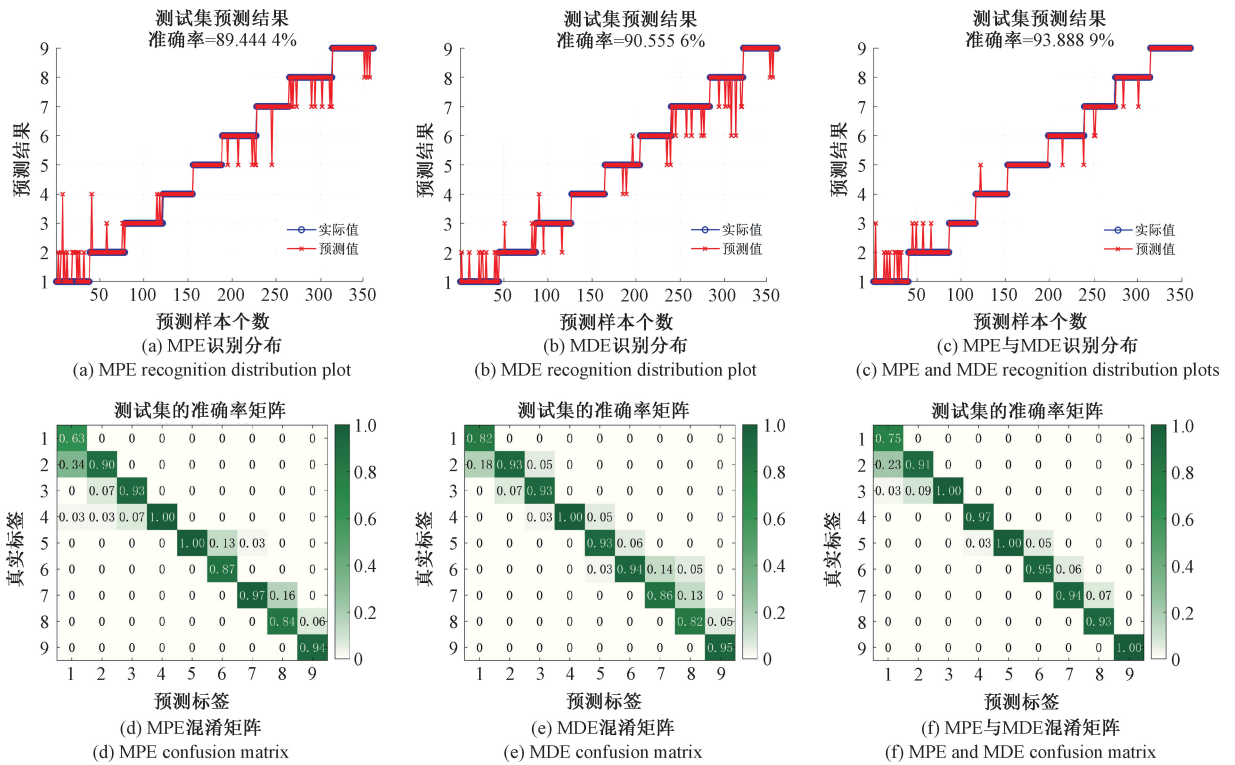


图 12 3 组数据集对应测试集的认识分布和混淆矩阵

Fig. 12 Recognition distribution plot and confusion matrix for the test set corresponding to three datasets

在 3.3 的分析中,已经验证了将 MPE 与 MDE 结合作为特征向量,相较于单一特征向量,能够显著提升识别性能。因此,对比实验选用 MPE 与 MDE 作为特征向量输入对比模型中,数据集同样按照 80%与 20%的比例,划分为训练集和测试集。单次实验的识别分布图和混淆矩阵如图 13 所示。

每种模型进行 10 次随机实验,实验结果如图 14 所示,并计算了平均识别准确率、精确率、召回率和 F1 值如表 4 所示。

1) 对比 CPO-RF 和 CPO-AdaBoost 单集成学习模型与 CPO-RF-AdaBoost 双集成学习模型,双集成学习模型的性能明显优于单集成学习模型。CPO-RF-AdaBoost 的性能显著提升,这表明通过结合 RF 和 AdaBoost 算法,两种算法的优势在集成过程中得到了良好利用,能够更有效地提升模型性能。

2) 在相同优化算法下对不同模型的对比中,CPO-SVM、CPO-LSSVM 与 CPO-RF-AdaBoost 的对比结果再次验证了双集成学习模型的优越性。SVM 和 LSSVM 虽然在某些场景下具有良好的表现,但与 CPO-RF-AdaBoost 相比,其准确率较低,这是因为双集成学习能更好地捕捉数据的复杂结构,从而提高模型的鲁棒性。

3) 通过对相同模型采用不同优化算法的对比中,能够发现优化算法对模型性能有明显影响,CPO-RF-AdaBoost 模型的平均识别准确率高于 HO-RF-AdaBoost 和 KOA-RF-AdaBoost 模型,这表明合适的优化算法能够与集成学习策略产生协同效应,进一步提升模型的性能。

综上所述,CPO-RF-AdaBoost 模型的平均识别准确率达到 94.50%,较 CPO-RF、CPO-AdaBoost、CPO-SVM、CPO-LSSVM、HO-RF-AdaBoost 和 KOA-RF-AdaBoost 六种模型的平均识别准确率分别提升了 3.78%、9.38%、11.33%、7.96%、1.94% 和 8.92%,验证了 CPO-RF-AdaBoost 模型对不同结垢厚度的均压电极具有良好的识别优势。

表 4 各模型性能对比

Table 4 Performance comparison of various models

模型	识别准确率/%	精确率/%	召回率	F1 值
CPO-RF	90.63	88.62	90.66	0.886 3
CPO-AdaBoost	85.12	84.45	85.08	0.892 9
CPO-SVM	83.17	83.16	83.76	0.825 1
CPO-LSSVM	86.54	89.53	86.44	0.892 9
HO-RF-AdaBoost	92.56	91.95	92.62	0.922 3
KOA-RF-AdaBoost	85.58	83.46	85.48	0.829 6
CPO-RF-AdaBoost	94.50	94.19	94.24	0.946 4

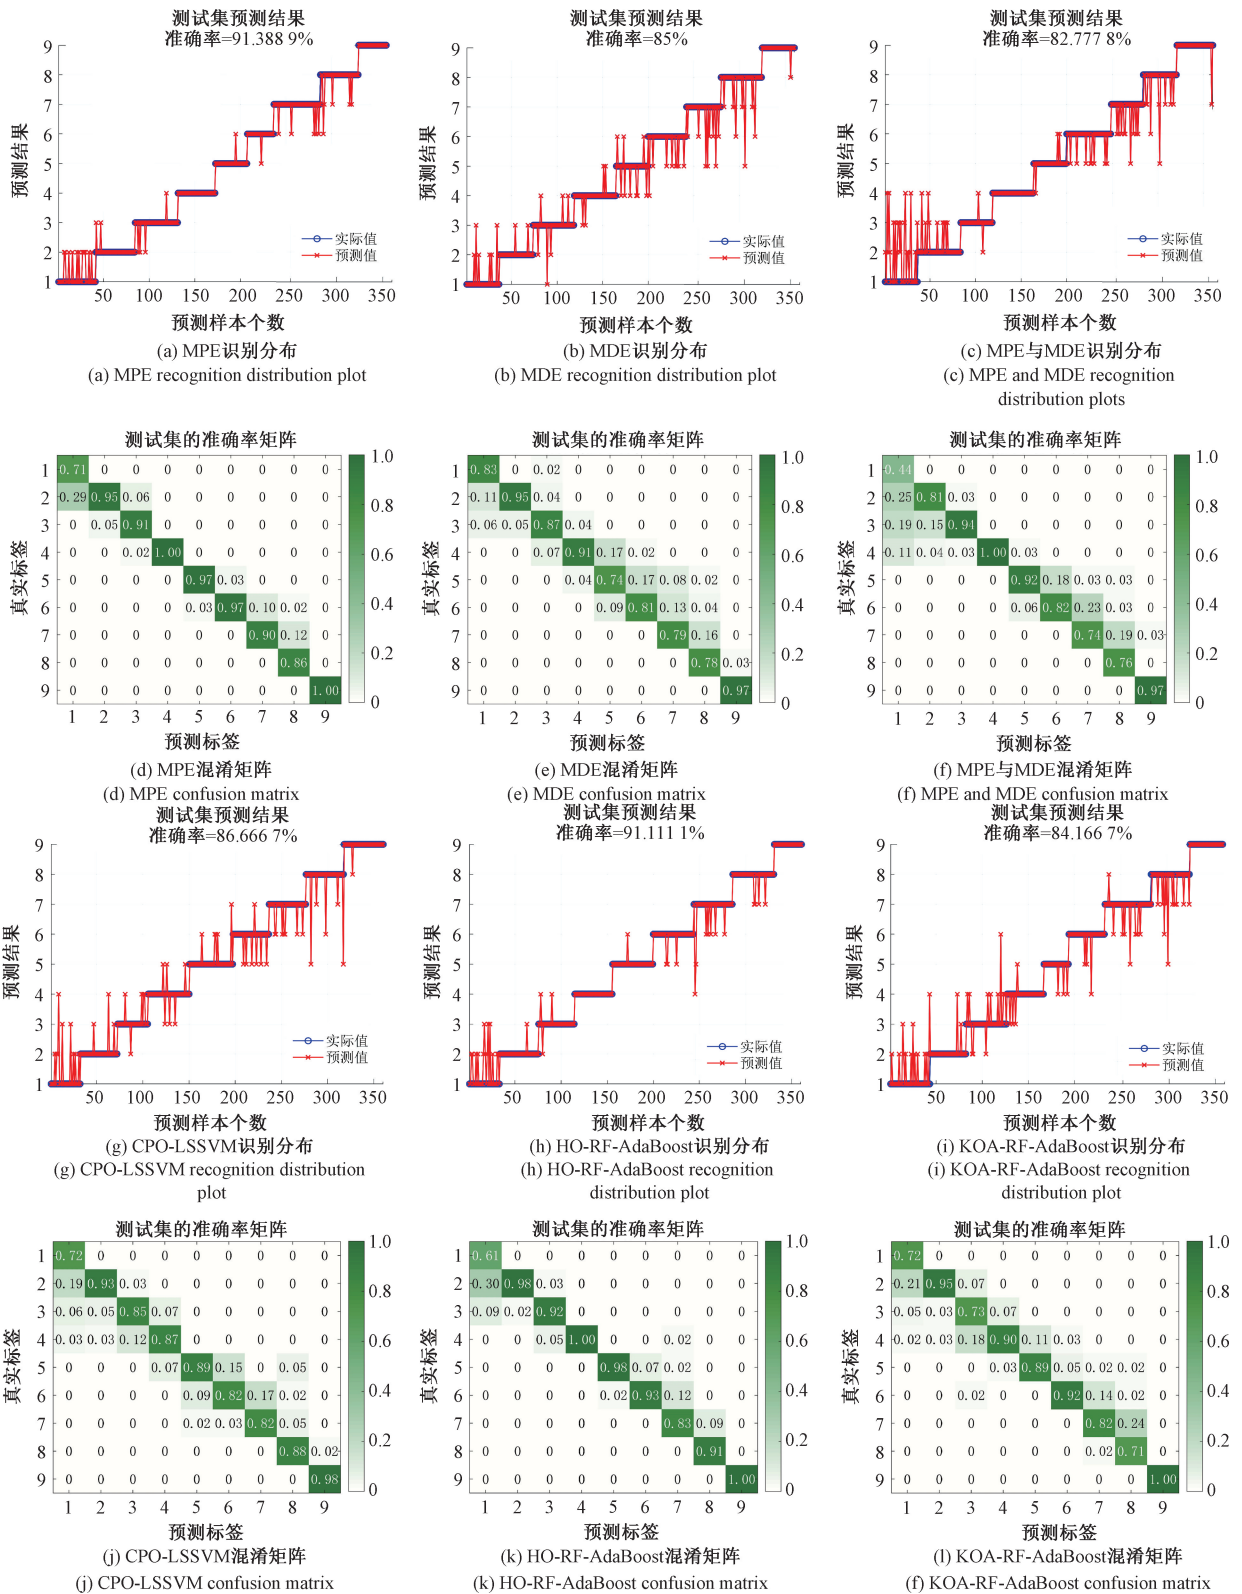


图 13 6 种模型单次实验的识别分布和混淆矩阵

Fig. 13 Recognition distribution plots and confusion matrices for six models in a single experiment

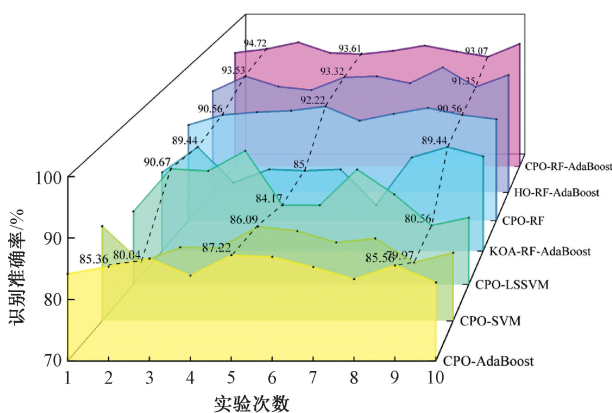


图 14 每种模型 10 次随机实验识别结果

Fig. 14 Recognition results of 10 random experiments for each model

## 4 结论

针对均压电极结垢超声回波检测法中结垢厚度识别精确度较低的问题,本文提出了一种结合多尺度熵的 SVM-CPO-RF-AdaBoost 均压电极结垢智能识别方法。采用 SVM 对超声回波信号进行分解,并根据模态选取方法筛选出有效信号成分进行重构,抑制信号中的高低频噪声;选用 MPE 和 MDE 作为均压电极超声回波信号的特征提取方法;构建了 CPO 优化的 RF-AdaBoost 双集成学习模型用于结垢厚度的识别。通过对比实验得出,结合 MPE 与 MDE 作为特征能够显著提高模型的识别准确率;CPO-RF-AdaBoost 模型的平均识别准确率达到 94.50%,且精确率、召回率和 F1 值均高于其他模型,充分证明所提方法对均压电极结垢厚度识别具有显著优势。后续将进一步优化模型架构,以提高复杂工况下均压电极结垢厚度的识别精度。

## 参考文献

[ 1 ] 贺婷婷,高兵,杨帆,等.电-流-传质场作用下的换流阀冷却系统均压电极垢层动态沉积特性研究[J]. 电工技术学报,2019,34(14):2863-2873.  
HE T T, GAO B, YANG F, et al. The dynamic deposition behavior of grading electrode in converter valve cooling system considering electro-velocity-mass transfer field [ J ]. Transactions of China Electrotechnical Society, 2019, 34(14): 2863-2873.

[ 2 ] 刘学忠,王晨星,刘宁,等.换流阀内水冷系统泄漏电流对散热器腐蚀的影响[J]. 高电压技术,2020,46(5):1781-1790.  
LIU X ZH, WANG CH X, LIU N, et al. Influence of leakage currents on corrosion of heat sinks in inner water cooling system for converter valve [ J ]. High Voltage

Engineering, 2020, 46(5): 1781-1790.

[ 3 ] GAO B, HE T T, YANG F, et al. Investigation on deposition behavior of HVDC water cooling system based on electro-mass transfer-velocity coupling model [ J ]. IEEE Access, 2019, 7: 67960-67971.

[ 4 ] 闫孝姮,光思辰,胡宇,等.换流阀冷却系统均压电极结垢超声导波检测方法研究[J]. 仪器仪表学报,2021,42(10):251-263.  
YAN X H, GUANG S CH, HU Y, et al. Investigation of ultrasonic guided wave mode conversion characteristics in grading electrodes sediments detection of the HVDC converter valve cooling system [ J ]. Chinese Journal of Scientific Instrument, 2021, 42(10): 251-263.

[ 5 ] 陈伟华,万晨,闫孝姮,等.基于 RWSSA-OMP-DBN 的均压电极结垢超声检测[J]. 传感技术学报,2022,35(2):154-161.  
CHEN W H, WAN CH, YAN X H, et al. Ultrasonic detection of scaling of equalizing electrode based on RWSSA-OMP-DBN [ J ]. Chinese Journal of Sensors and Actuators, 2022, 35(2): 154-161.

[ 6 ] CHEN W H, CHEN H Q, YAN X H, et al. Hybrid entropy in the time-frequency domain for grading electrode sediment identification [ J ]. IEEE Access, 2022, 10: 54751-54763.

[ 7 ] 刘骁眸,马旭,金石炜,等.CEEMD 和 IBAS-SVM 特高压换流站均压电极结垢识别方法[J]. 中国测试,2023,49(6):172-180.  
LIU X M, MA X, JIN SH W, et al. Sediment identification method for grading electrodes in HVDC converter station based on CEEMD and IBAS-SVM [ J ]. China Measurement & Test, 2023, 49(6): 172-180.

[ 8 ] DONG X B, YU Z W, CAO W M, et al. A survey on ensemble learning [ J ]. Frontiers of Computer Science, 2019, 14(2): 241-258.

[ 9 ] GANAIE M A, HU M H, MALIK A K, et al. Ensemble deep learning: A review [ J ]. Engineering Applications of Artificial Intelligence, 2022, 115: 105151.

[ 10 ] 常梦容,王海瑞,肖杨.mRMR 特征筛选和随机森林的故障诊断方法研究[J]. 电子测量与仪器学报,2022,36(3):175-183.  
CHANG M R, WANG H R, XIAO Y. Research on fault diagnosis method based on mRMR feature screening and random forest [ J ]. Journal of Electronic Measurement and Instrumentation, 2022, 36(3): 175-183.

[ 11 ] CHENG S H, WU L Y, ZHANG S J, et al. A model for lumbar EMG signal recognition based on stacking integration learning [ J ]. IEEE Sensors Journal, 2023, 23(4): 3766-3775.

- [12] ZHAO C C, LIANG H Y, SHAN Y, et al. Bearing fault diagnosis method based on comprehensive information divergence and improved BP-AdaBoost algorithm [J], *Structural Health Monitoring*, 2023, 22(5): 3047-3064.
- [13] 刘琼,张豹. 基于 GBDT 算法的锂电池剩余使用寿命预测 [J]. *电子测量与仪器学报*, 2022, 36(10): 166-172.  
LIU Q, ZHANG B. Remaining useful life remaining useful lifetime prediction for lithium battery based on GBDT algorithm [J]. *Journal of Electronic Measurement and Instrumentation*, 2022, 36(10): 166-172.
- [14] 刘馨雅,马超,黄民,等. 变转速工况下基于角度重采样与 PCA-XGBoost 轴承故障诊断方法研究 [J]. *电子测量与仪器学报*, 2024, 38(3): 45-54.  
LIU X Y, MA CH, HUANG M, et al. Research on angle resampling and PCA-XGBoost bearing fault diagnosis method under variable speed working condition [J]. *Journal of Electronic Measurement and Instrumentation*, 2024, 38(3): 45-54.
- [15] DHANANJAY B, SIVARAMAN J. Analysis and classification of heart rate using CatBoost feature ranking model [J]. *Biomedical Signal Processing and Control*, 2021, 68: 102610.
- [16] 谢国民,江海洋. 基于 Adaboost-INGO-HKELM 的变压器故障辨识 [J]. *电力系统保护与控制*, 2024, 52(5): 94-104.  
XIE G M, JIANG H Y. Transformer fault identification based on Adaboost-INGO-HKELM [J]. *Power System Protection and Control*, 2024, 52(5): 94-104.
- [17] 郑伟宏,朱峰刚,王小娟,等. 基于 PCA-Adaboost-GBDT 的短期风电功率预测 [J]. *电气自动化*, 2024, 46(4): 80-83.  
ZHENG W H, ZHU F G, WANG X J, et al. Short-term wind power prediction based on PCA-Adaboost-GBDT [J]. *Electrical Automation*, 2024, 46(4): 80-83.
- [18] YUN F, YU Z W, YANG K X, et al. AdaBoost-Stacking based on incremental broad learning system [J]. *IEEE Transactions on Knowledge and Data Engineering*, 2024, 36(12): 7585-7599.
- [19] 高兵,黄驰,黄晨浩,等. 换流阀冷却系统均压电极垢层沉积声学检测方法 [J]. *电工技术学报*, 2024, 39(23): 7319-7330.  
GAO B, HUANG CH, HUANG CH H, et al. Study on acoustic detection method for sediment on grading electrodes in converter valve cooling system [J]. *Transactions of China Electrotechnical Society*, 2024, 39(23): 7319-7330.
- [20] GAO J, YUAN H, YANG AI J, et al. A fault detection

method based on successive variational mode decomposition for the energy absorption branch of modular DC circuit breakers [J], *IEEE Transactions on Power Delivery*, 2023, 38(5): 3688-3700.

- [21] LI J Y, SHANG P J, ZHANG X Z. Financial time series analysis based on fractional and multiscale permutation entropy [J]. *Communications in Nonlinear Science and Numerical Simulation*, 2019, 78: 105-113.
- [22] KAFANTARIS E, MILLY L, ESCUDERO J. Stratified multivariate multiscale dispersion entropy for physiological signal analysis [J], *IEEE Transactions on Biomedical Engineering*, 2023, 70(3): 1024-1035.
- [23] WEN L F, LI Y L, ZHAO W B, et al. Predicting the deformation behaviour of concrete face rockfill dams by combining support vector machine and AdaBoost ensemble algorithm [J], *Computers and Geotechnics*, 2023, 161: 105611.
- [24] ABDEL-BASSET M, MOHAMED R, ABOUHAWWASH M. Crested porcupine optimizer: A new nature-inspired metaheuristic [J]. *Knowledge-Based Systems*, 2024, 284: 111257.

## 作者简介



闫孝姮(通信作者), 2016 年于辽宁工程技术大学获得博士学位, 现为辽宁工程技术大学教授, 主要研究方向为电磁超声探测与成像和人工智能与模式识别。

E-mail: xiaohengyan@163.com

**Yan Xiaoheng** (Corresponding author) received her Ph. D. degree from Liaoning Technical University in 2016. Now she is a professor at Liaoning Technology University. Her main research interests include electromagnetic ultrasonic detection and imaging, artificial intelligence and pattern recognition.



王治仁, 2023 年于辽宁工程技术大学获得学士学位, 现为辽宁工程技术大学硕士研究生, 主要研究方向为电磁超声探测与成像。

E-mail: wzrenhance@163.com

**Wang Zhiren** received his B. Sc. degree from Liaoning Technical University in 2023. Now he is a M. Sc. candidate at Liaoning Technical University. His main research interest includes electromagnetic ultrasonic detection and imaging.



赵一澄, 2024 年于辽宁工程技术大学获得硕士学位, 现为国网辽宁省电力有限公司辽阳供电公司工程师, 主要研究方向为人工智能与模式识别。

E-mail: 1059021312@qq.com

**Zhao Yicheng** received his M. Sc. degree

from Liaoning Technical University in 2024. Now he is an engineer at Liaoyang Power Supply Company of State Grid Liaoning Province Electric Power Co., Ltd. His main research interest includes artificial intelligence and pattern recognition.



**陈伟华**, 2016 年于辽宁工程技术大学获得博士学位, 现为辽宁工程技术大学副教授, 主要研究方向为无线电能传输技术和电磁超声探测与成像。

E-mail: fxlgd@163.com

**Chen Weihua** received his Ph. D. degree from Liaoning Technical University in 2016. Now he is an associate professor at Liaoning Technical University. His main

research interests include wireless energy transmission technology, electromagnetic ultrasonic detection and imaging.



**张维广**, 2023 年于辽宁工程技术大学获得学士学位, 现为辽宁工程技术大学硕士研究生, 主要研究方向为电磁超声探测与成像。

E-mail: zwgoood@163.com

**Zhang Weiguang** received his B. Sc. degree from Liaoning Technical University in 2023. Now he is a M. Sc. candidate at Liaoning Technical University. His main research interest includes electromagnetic ultrasonic detection and imaging.