

基于 ICEEMDAN 多尺度模糊熵和 MVO-KELM 的变压器绕组铁心机械故障诊断^{*}

崔 星¹, 陈 静¹, 孙婧琪², 杜 瑞³, 毛瑞新¹, 吴金利⁴

(1. 国网江苏省电力有限公司丹阳供电分公司, 江苏 丹阳 212300;

2. 国网江苏省电力有限公司镇江供电分公司, 江苏 镇江 212002;

3. 国网江苏省电力有限公司句容市供电分公司, 江苏 句容 212400;

4. 河海大学 能源与电气学院, 江苏 南京 211100)

摘 要: 针对变压器绕组铁心机械故障诊断精度不足的问题, 提出了一种基于改进自适应白噪声完整集成经验模态分解 (ICEEMDAN) 多尺度模糊熵 (MFE) 和多元宇宙优化算法优化核极限学习机 (MVO-KELM) 的变压器绕组铁心机械故障诊断方法。首先, 为了避免虚假模态分量的产生, 采用改进的 ICEEMDAN 对变压器原始振动信号进行分解。其次, 利用 Pearson 相关系数法选取相关性最高的模态分量, 并计算其 MFE 值。然后, 将 MFE 值作为特征量构建特征数据集, 并利用 MVO 优化 KELM 的核参数和正则化系数。最后, 将特征数据集输入所建 MVO-KELM 模型进行分类识别, 实现高准确率诊断目标。试验结果表明, 所提方法具有优秀的诊断精度和稳定性, 能够精确诊断变压器绕组铁心不同松动程度的故障, 诊断准确率达到 99% 以上, 可为变压器现场检修策略的制定提供一定的指导。

关键词: 电力变压器; 绕组铁心; 故障诊断; 多元宇宙优化算法; 核极限学习机

中图分类号: TM41 文献标志码: A 文章编号: 1673-6540(2023)10-0081-10

doi: 10.12177/emca.2023.113

Mechanical Fault Diagnosis for Transformer Winding Core Based on ICEEMDAN Multi-Scale Fuzzy Entropy and MVO-KELM^{*}

CUI Xing¹, CHEN Jing¹, SUN Jingqi², DU Rui³, MAO Ruixin¹, WU Jinli⁴

(1. Danyang Power Supply Branch, State Grid Jiangsu Electric Power Co., Ltd., Danyang 212300, China;

2. Zhenjiang Power Supply Branch, State Grid Jiangsu Electric Power Co., Ltd., Zhenjiang 212002, China;

3. Jurong Power Supply Branch, State Grid Jiangsu Electric Power Co., Ltd., Jurong 212400, China;

4. College of Energy and Electrical Engineering, Hohai University, Nanjing 211100, China)

Abstract: A transformer winding core mechanical fault diagnosis method based on improved complete ensemble empirical mode decomposition with adaptive noise (ICEEMDAN) multi-scale fuzzy entropy (MFE) and multi-verse optimizer algorithm optimized kernel based extreme learning machine (MVO-KELM) is proposed for the problem of

收稿日期: 2023-05-21; 收到修改稿日期: 2023-06-16

^{*} 基金项目: 国网江苏省电力有限公司重点科技项目 (J2020040)

作者简介: 崔 星 (1993—), 男, 硕士, 中级工程师, 研究方向为电力设备故障诊断。

陈 静 (1998—), 女, 本科, 助理级工程师, 研究方向为电机分析。

孙婧琪 (1999—), 女, 本科, 助理级工程师, 研究方向为电力设备故障诊断。

杜 瑞 (1999—), 男, 本科, 研究方向为电力系统自动控制、信息处理等。

毛瑞新 (1998—), 男, 本科, 研究方向为电力设备故障诊断。

吴金利 (1966—), 男, 硕士研究生, 研究方向为电力设备故障诊断。

insufficient accuracy of transformer winding core mechanical fault diagnosis. Firstly, to avoid the generation of spurious modal components, the original transformer vibration signal is decomposed using a modified ICEEMDAN. Secondly, the modal component with the highest correlation is selected using the Pearson correlation coefficient method and its MFE value is calculated. Then, the MFE values are used as feature quantities to construct feature datasets, and the kernel parameters and regularization coefficients of KELM are optimized using MVO. Finally, the feature dataset is input into the constructed MVO-KELM model for classification and identification to achieve the goal of high accuracy diagnosis. The experimental results prove that the proposed approach possesses excellent diagnostic accuracy and stability, and can accurately diagnose transformer winding core loosening faults of different degrees with a diagnostic accuracy of more than 99%, which may supply the necessary guidance for the development of transformer field maintenance strategy.

Key words: power transformer; winding core; fault diagnosis; multi-verse optimizer algorithm; kernel based extreme learning machine

0 引言

电力变压器作为电网中的重要设备,在电能传输、电压变换和隔离保护等多个方面发挥着至关重要的作用,对保障电网的安全稳定运行具有重要意义^[1]。变压器长期运行过程中会受到机械力、电磁力、热等多种因素的作用,可能诱发绕组松动、铁心松动、绕组变形和硅钢片磨损等机械故障^[2]。而这些机械故障通常具有累积效应,若未能及时发现将导致严重的变压器故障,可能会造成大面积停电,从而产生严重的经济损失。因此,开展变压器绕组铁心机械故障诊断研究具有重要意义。

当前,常用的变压器机械故障诊断方法有低压脉冲法、频响法、短路阻抗法、振动法、超声波检测法和视频窥视技术等^[3-4]。其中,振动法凭借其直接与电力设备无直接电气连接,并且具有高可靠性、高灵敏度以及便于操作等优点,倍受学者们的关注,被广泛应用于航空航天、电力设备故障诊断等领域^[5-6]。文献[7]利用变压器振动信号对其内部绕组机械结构变化进行诊断,得出振动特征参量可有效反映绕组松动、变形等机械机构变化。从而表明变压器振动信号中蕴藏着丰富的状态信息,可有效表征当前机械状态。

利用振动分析法进行变压器机械故障诊断的关键在于特征量提取。目前,振动信号特征量提取方法主要有:经验模态分解、小波变换和相空间重构技术等^[8]。文献[9]利用改进集合经验模态分解(EEMD)提取了变压器振动信号特征量,用于识别铁心状态变化,有效解决了模态混叠的问题,但是引入了额外的白噪声导致提取的特征量误差偏大,严重影响了状态识别结果。文献[10]

利用自适应白噪声完整集成经验模态分解(CEEMDAN)进行振动信号特征量提取,解决了EEMD额外引入白噪声导致的干扰问题,提高了特征量提取的准确度,但仍存在虚假模态的问题。基于此,本文对CEEMDAN进一步改进以解决虚假模态问题,采用改进的CEEMDAN(ICEEMDAN)完成振动信号的模态分解和特征量提取。

此外,准确识别特征量也是完成故障诊断的核心步骤。机器学习智能识别算法具有仅凭借小样本量数据即可实现高诊断精度的优势,被广泛应用于故障诊断领域。常用的机器学习算法包括:随机森林、概率神经网络和核极限学习机(KELM)等^[11]。考虑到KELM算法的稳定性和强鲁棒性,本文采用KELM对所提特征量进行识别诊断。文献[12]利用KELM对滚动轴承振动信号的多尺度排列熵特征进行分类识别,实现了轴承故障状态的诊断,但是由于KELM的核参数并未最优选取,导致了诊断准确率不高。针对该问题,本文采用多元宇宙优化算法(MVO)对KELM的主要参数进行优化,以实现最高诊断准确率。MVO具有结构简单、寻优能力强等优点,已被广泛应用于电力负荷预测、优化调度和参数辨识等多个领域^[13]。

综上所述,本文提出一种基于ICEEMDAN多尺度模糊熵和MVO-KELM的变压器绕组铁心机械故障诊断方法,对变压器绕组铁心不同松动程度的故障进行诊断识别。首先,采用ICEEMDAN对变压器振动信号进行分解;其次,选取与原始振动信号相关性最高的模态分量IMF进行多尺度模糊熵(MFE)值的计算,并利用MFE值构建特征

集;然后,为实现高准确率诊断,利用 MVO 对 KELM 关键参数进行优化,建立 MVO-KELM 诊断模型;再次,将特征数据集输入 SVO-KELM 模型中完成识别诊断;最后,利用试验数据验证了所提方法的有效性,与其他诊断模型的对比证明了所提诊断模型的优越性。

1 基于 ICEEMDAN 和多尺度模糊熵的变压器振动信号特征提取

1.1 ICEEMDAN 的基本原理

ICEEMDAN 算法是在 CEEMDAN 的基础上改进得到。传统的 EMD 分解结果存在严重的模态混叠现象,而 EEMD 通过添加白噪声在一定程度上消除了模态混叠,然而所引入的白噪声难以去掉,导致信号的重构误差增大^[9]。为了解决重构误差的问题,学者们提出了 CEEMDAN 算法,CEEMDAN 通过添加正负相抵的白噪声,解决了引入白噪声导致的干扰问题,提高了信号重构准确度。然而,CEEMDAN 仍存在虚假模态分量的问题。

ICEEMDAN 通过引入 EMD 分解所得的模态分量,以解决引入额外白噪声导致的干扰和虚假模态问题。具体地,ICEEMDAN 计算步骤如下^[14]。

步骤(a),在初始振动信号 x 中添加白噪声 $E_1[\vartheta^{(i)}]$,则有:

$$x^{(i)} = x + \xi_1 E_1[\vartheta^{(i)}] \quad (1)$$

式中: ξ_1 为第 1 个信噪比; $E_1[\vartheta^{(i)}]$ 为 EMD 分解得到的第 1 个 IMF 值; $\vartheta^{(i)}$ 为添加的第 i 个白噪声。

步骤(b),利用 EMD 对加噪信号进行分解,获取 1 阶残差 R_1 和相应的模态分量为

$$\begin{cases} R_1 = \frac{1}{I} \sum_{i=1}^I M[x^{(i)}] \\ \sigma_1 = x - R_1 \end{cases} \quad (2)$$

式中: R_1 为 1 阶残差余项; σ_1 为第 1 个 IMF 分量; $M[x^{(i)}]$ 为添加白噪声后的信号。

步骤(c),求解第 2 个 IMF 分量为

$$\begin{cases} R_2 = \frac{1}{I} \sum_{i=1}^I M\{R_1 + \xi_2 E_2[\vartheta^{(i)}]\} \\ \sigma_2 = R_1 - R_2 \end{cases} \quad (3)$$

式中: R_2 为 2 阶残差余项; σ_2 为第 2 个 IMF 分量; ξ_2 为第 2 个信号比。

步骤(d),按照上述步骤类推得到第 k 个 IMF 的分量和 k 阶残差余项为

$$\begin{cases} R_k = \frac{1}{I} \sum_{i=1}^I M\{R_{k-1} + \xi_k E_k[\vartheta^{(i)}]\} \\ \sigma_k = R_{k-1} - R_k \end{cases} \quad (4)$$

式中: $k=1,2,\dots,N$; R_k 为 k 阶残差余项, σ_k 为第 k 个 IMF 分量。

步骤(e),重复步骤(d),直到剩余信号达到结束条件,从而获得全部模态分量,振动信号最后被分解为

$$x = \sum_{k=1}^N \sigma_k + R \quad (5)$$

根据上述步骤可得到由 ICEEMDAN 算法分解的 IMF 分量和残差余项。进一步地,选取与原始振动信号相关性最高的 IMF 分量。

1.2 PEARSON 相关系数

为了选取与变压器振动信号相关性最高的模态分量,本文采用 Pearson 相关系数计算不同模态分量与原始振动信号的相关性。Pearson 相关系数可有效表征两个变量之间的关联程度,其值分布在区间 $[-1,1]$ 上,其值越大意味着相关性越高^[15]。Pearson 相关系数的求解公式如下。

设两个不同的参量分别为 $A = \{a_1, a_2, \dots, a_n\}$, $B = \{b_1, b_2, \dots, b_n\}$, 则 A 与 B 的 Pearson 相关系数为

$$\rho_{AB} = \frac{\sum_{i=1}^n [a_i - E(A)][b_i - E(B)]}{\sqrt{\sum_{i=1}^n [a_i - E(A)]^2} \sqrt{\sum_{i=1}^n [b_i - E(B)]^2}} \quad (6)$$

式中: ρ_{AB} 为 Pearson 相关系数, $E(A)$ 和 $E(B)$ 为两个参量的均值。

1.3 多尺度模糊熵

根据上文可得到相关性最高的模态分量,接下来进一步计算相关性最高的模态分量的多尺度模糊熵(MFE),以构建诊断模型的特征数据集。MFE 是在模糊熵(FE)的基础上加入尺度因子构建得到的,能够反映时间序列在不同尺度条件下的复杂性及系统的多模式信息和动力学特性变化。FE 详细计算步骤参考文献[16],MFE 具体求解方法如下^[17]:

(1) 对于时间序列 $M = \{\zeta_1, \zeta_2, \dots, \zeta_N\}$, 构造

向量 $\mathbf{Y}_i^m$, 其中 N 和 m 分别为维度数:

$$\mathbf{Y}_i^m = \{\zeta(i), \zeta(i+1), \dots, \zeta(i+m-1) - \zeta_0(i)\} \quad (7)$$

$$\zeta_0(i) = \frac{1}{m} \sum_{j=0}^{m-1} \zeta(i+j) \quad (8)$$

(2) 求解两个向量的距离:

$$d_{ij}^m = d[\mathbf{Y}_m(i) - \mathbf{Y}_m(j)] = \max\{|z_{i+l-1} - z_{j+l-1}|, l = 1, 2, \dots, m\}, i \neq j \quad (9)$$

(3) 根据模糊函数 $\mu(d_{ij}^m, n, r)$ 定义 $\mathbf{Y}_m(i)$ 与 $\mathbf{Y}_m(j)$ 的相似度为 D_{ij}^m , 可表示为

$$D_{ij}^m = \mu(d_{ij}^m, n, r) = e^{-\ln 2(d_{ij}^m/r)^n} \quad (10)$$

式中: $\mu(d_{ij}^m, n, r)$ 为模糊隶属度函数, r 为宽度, n 为边界梯度。

(4) 平均相似度函数定义为

$$\phi^m(n, r) = \frac{1}{N-m} \sum_{i=1}^{N-m} \left(\frac{1}{N-m-1} \sum_{j=1}^{N-m} D_{ij}^m \right) \quad (11)$$

依据上述步骤(1)至步骤(4)构建如式(12)的 $m+1$ 维向量:

$$\phi^{m+1}(n, r) = \frac{1}{N-m} \sum_{i=1}^{N-m} \left(\frac{1}{N-m-1} \sum_{j=1}^{N-m} D_{ij}^{m+1} \right) \quad (12)$$

(5) 从而得到 FE 的表达式为

$$FE(m, n, r, N) = \ln \phi^m(n, r) - \ln \phi^{m+1}(n, r) \quad (13)$$

(6) 对 $\mathbf{M}$ 进行粗粒化处理, 得到新的时间序列为

$$\mathbf{y}_j(\tau) = \frac{1}{\tau} \sum_{i=(j-1)\tau+1}^{j\tau} \zeta_i, 1 \leq j \leq \frac{N}{\tau} \quad (14)$$

式中: $\tau = 1, 2, \dots, n$ 为尺度因子, 原时间序列被依次分成长度为 N/τ 的粗粒向量。

(7) 将得到的 τ 组粗粒化序列分别计算其 FE , 并把熵值描述成与尺度因子相关的函数。

通过上述步骤, 可以求出在取不同尺度因子时相关性最高的 IMF 分量的 MFE 值, 能有效避免低相关性 IMF 分量导致的特征冗余问题。

2 基于多元宇宙算法优化的 KELM 模型

2.1 KELM 算法基本原理

KELM 本质为一种单隐层前馈神经网络算

法, 是在极限学习机算法 (ELM) 中引入核函数所建立的。KELM 具有分类性能稳定、鲁棒性强和广义性能好等优点^[18]。因此, 本文利用 KELM 算法对变压器绕组铁心机械状态进行故障诊断建模。KELM 算法的具体实现过程如下:

对于任意 N 组样本 $\{(z_i, t_i)\}_{i=1}^N$, 若 ELM 的隐藏层节点数为 k , 激活函数为 $g(\cdot)$, 则可表示为

$$\mathbf{H}\boldsymbol{\beta} = \mathbf{T} \quad (15)$$

$$\mathbf{H} = \begin{bmatrix} g(\omega_1 z_1 + b_1) & \cdots & g(\omega_k z_1 + b_k) \\ \vdots & & \vdots \\ g(\omega_1 z_\eta + b_1) & \cdots & g(\omega_k z_\eta + b_k) \end{bmatrix}_{\eta \times k} \quad (16)$$

式中: $\mathbf{H}$ 是隐含层输出矩阵; $\boldsymbol{\beta}$ 是输出权重向量; $\mathbf{T}$ 是目标输出矩阵; ω_k 为权重, b_k 为神经元阈值。

根据文献[18]可知, ELM 的学习环节可通过最小二乘法计算最优解进行等价。为了增强算法的自适应性与稳定性, 采用正则化系数 C 进行计算, 求得最小二乘解:

$$\boldsymbol{\beta} = \mathbf{H}^+ \mathbf{T} = \mathbf{H}^T \left(\mathbf{H}\mathbf{H}^T + \frac{\mathbf{I}}{C} \right)^{-1} \mathbf{T} \quad (17)$$

式中: $\mathbf{H}^+$ 为 $\mathbf{H}$ 的广义逆矩阵, $\mathbf{I}$ 为单位对角矩阵。

根据 Mercer 定理, 核矩阵为

$$\begin{cases} \boldsymbol{\Omega} = \mathbf{H}\mathbf{H}^T \\ \Omega_{ij} = h(z_i)h(z_j) = K(z_i, z_j) \end{cases} \quad (18)$$

式中: $K(\cdot)$ 代表核函数。

为了提高计算速率, 减少参数设置, 本文选用径向基核函数:

$$K(z_i, z_j) = \exp\left(-\frac{\|z_i - z_j\|^2}{2\gamma^2}\right) \quad (19)$$

式中: γ 为核参数。

进一步地, KELM 的诊断输出函数为

$$\begin{aligned} \mathbf{O}(z) &= \mathbf{h}(z)\boldsymbol{\beta} = \mathbf{h}(z)\mathbf{H}^T \left(\mathbf{H}\mathbf{H}^T + \frac{\mathbf{I}}{C} \right)^{-1} \mathbf{T} = \\ & \begin{bmatrix} K(z, z_1) \\ \vdots \\ K(z, z_k) \end{bmatrix} \left(\boldsymbol{\Omega} + \frac{\mathbf{I}}{C} \right)^{-1} \mathbf{T} \end{aligned} \quad (20)$$

根据上述原理可知, 参数 C 与 γ 值的选取将直接影响 KELM 诊断性能的发挥。因此, 为了充分发挥 KELM 的诊断性能, 本文选用 MVO 算法对 C 和 γ 的取值进行优化选择。

2.2 MVO-KELM 诊断模型

针对 KELM 中关键参数取值影响算法性能发挥的问题,本文采用 MVO 对 KELM 中正则化系数 C 和核参数 γ 进行优选,以实现高诊断准确率的目标。

MVO 中宇宙代表问题的一个可行解,解中的变量与宇宙中的物体相对应,算法适应度值用宇宙膨胀率表示,白洞与黑洞分别代表高膨胀率与低膨胀率,物质通过虫洞实现黑洞和白洞之间的移动^[13]。MVO 算法的基本原理如下^[13]:

(1) 宇宙中高膨胀率的物体总是向低膨胀率的物体发展;

(2) 相邻白洞与黑洞间的物体转移依靠虫洞实现,并更新宇宙位置,更新公式为

$$X_p^q = \begin{cases} X_k^q, & r_1 < N(U_p) \\ X_p^q, & r_1 \geq N(U_p) \end{cases} \quad (21)$$

式中: X_p^q 为第 p 个宇宙中第 q 个变量; X_k^q 为通过轮盘赌机制选取的第 k 个宇宙中第 q 个变量; U 为宇宙种群; $N(U_p)$ 为标准膨胀率; $r_1 \in [0, 1]$ 为随机数。

(3) 当不同最优宇宙依靠虫洞进行物体转移时,须更新宇宙位置,更新公式为

$$X_p^q = \begin{cases} X_p + R \times [(u_q - p_q) \times r_4 + p_q], & r_3 < 0.5 \quad r_2 < W \\ X_q - R \times [(u_q - p_q) \times r_4 + p_q], & r_3 \geq 0.5 \quad r_2 < W \\ X_p^q, & r_2 \geq W \end{cases} \quad (22)$$

式中: X_q 为当前最优宇宙中第 q 个变量, u_q 为最大值; p_q 为最小值; r_2, r_3, r_4 在区间 $[0, 1]$ 内随机取值; W 为虫洞的存在率; R 为旅行距离率。

本文利用 MVO 对 KELM 关键参数进行优化,构建适应度函数为

$$\begin{cases} \max & s(C, \gamma) = \frac{R_{num}}{T_{num}} \times 100\% \\ \text{s. t.} & C \in [C_{min}, C_{max}] \\ & \gamma \in [\gamma_{min}, \gamma_{max}] \end{cases} \quad (23)$$

式中: R_{num} 为分类正确样本数; T_{num} 为总样本数; $[C_{min}, C_{max}]$ 为参数 C 的取值范围; $[\gamma_{min}, \gamma_{max}]$ 为核参数 γ 的取值范围。

具体地, MVO-KELM 诊断模型的流程如图 1 所示。




图 1 MVO-KELM 诊断模型流程图

3 基于 ICEEMDAN-MFE 和 MVO-KELM 的变压器绕组铁心机械故障诊断方法

本文所提基于 ICEEMDAN-MFE 和 MVO-KELM 的变压器绕组铁心机械故障诊断方法的详细步骤如下。

步骤(1): 采集变压器箱体振动信号, 并对振动信号进行降噪预处理;

步骤(2): 采用 ICEEMDAN 算法分解处理后的变压器振动信号, 获取多个模态分量 IMF;

步骤(3): 利用 Pearson 相关系数计算不同模态分量与原振动信号的关联性, 并选取相关性最高的模态分量 IMF;

步骤(4): 计算相关性最强 IMF 分量的 MFE 值, 并将不同尺度的 MFE 值构建为特征数据集;

步骤(5): 将特征数据集输入本文建立的 MVO-KELM 诊断模型中进行识别;

步骤(6): 判断是否完成变压器绕组铁心机械状态诊断, 若是则输出诊断结果, 否则返回步骤(5)进行识别诊断。

综上, 本文所提基于 ICEEMDAN-MFE 和 MVO-KELM 的变压器绕组铁心机械故障诊断方法流程图如图 2 所示。

4 试验验证与对比分析

4.1 试验验证

为了验证所提方法的有效性, 本文以一台型




图2 基于ICEEMDAN-MFE和MVO-KELM的变压器故障诊断流程图

号为S13-M-200/10的变压器为研究对象,搭建了试验平台,进行了绕组铁心不同松动程度的故障模拟试验。故障模拟试验原理如图3所示。




图3 10 kV 电力变压器故障模拟试验原理示意图

在10 kV 变压器试验平台中,本文模拟了额定电压下变压器正常状态和三种典型机械故障状态:绕组铁心松动25%状态、绕组铁心松动50%状态和绕组铁心松动75%状态。具体地,利用数显扭矩扳手对绕组紧固螺栓和铁心压紧螺母进行松动,实现不同松动程度的故障模拟。振动信号采集仪采用DSP140801型采集仪,传感器选用1A212E型压电式加速度传感器,采样频率为16 kHz。为了便于信号采集,试验中振动信号测点主要布设于变压器顶部,其测点布设位置如图4所示。

进一步地,利用试验所得变压器不同状态试验数据验证本文所提方法的有效性。考虑到文章的可读性,以3号测点位置测得的振动信号为例




图4 变压器顶部测点布设位置图

展开分析,其不同状态的振动信号如图5所示。






图5 3号测点位置变压器正常与故障状态振动信号

由图5可知,变压器绕组铁心发生不同程度松动故障后,振动信号的幅值和波形发生明显变化。为了提取振动信号蕴藏的特征信息,利用ICEEMDAN对变压器四种状态的振动信号进行分解,所得分解结果如图6所示,图中Res为残差余项。同时,为了验证ICEEMDAN比EEMD具有更好的特征提取效果,本文利用EEMD对变压器振动信号进行分解,分解结果如图7所示。值得注意的是,为了防止分解过剩情况的出现,同时结合经验判断,本文将不同状态的模态分量数量均选择为7。


由图6可知,变压器不同状态振动信号的分解结果不同,同一振动信号的不同阶IMF分量不同,避免了额外加入白噪声导致的干扰及虚假模




(a) 正常状态



(b) 绕组铁芯松动25%状态




(c) 绕组铁芯松动50%状态




(d) 绕组铁芯松动75%状态


图6 ICEEMDAN 分解结果图




(a) 正常状态



(b) 绕组铁芯松动25%状态



(c) 绕组铁芯松动50%状态



(d) 绕组铁芯松动75%状态

图7 EEMD 分解结果图

态的产生。经过 ICEEMDAN 分解可有效提取振动信号的特征量。

由图 7 可知,由 EEMD 分解得到的 IMF 分量重构误差较大,特别是上述 4 种不同状态下的 IMF5 分量。由于引入额外白噪声未抵消,导致所

得 IMF5 分量的波形存在噪声干扰,与实际分量的误差较大。从而证明,所提 ICEEMDAN 在振动信号特征提取准确度方面优于 EEMD,具有一定的优越性。

进一步地,为了防止特征冗余情况的出现,采

用 Pearson 相关系数法计算由 ICEEMDAN 分解得到的 IMF 分量与原始振动信号的相关性强弱。变压器不同状态的模态分量 IMF 与振动信号的相关性强弱曲线如图 8 所示。




图 8 不同模态分量的 Pearson 相关系数值

由图 8 可知,变压器正常状态、绕组铁心松动 25% 和绕组铁心松动 75% 状态时的 IMF5 模态分量与原始振动信号的相关性最高,绕组铁心松动 50% 状态时 IMF4 模态分量与原始振动信号的相关性最高。因此,本文选择正常状态、绕组铁心松动 25% 和绕组铁心松动 75% 状态下的 IMF5 模态分量,及绕组铁心松动 50% 状态下的 IMF4 模态分量进行 MFE 计算。进一步地,计算上述状态对应 IMF5 模态分量和 IMF4 模态分量的 MFE 值,所得不同状态不同尺度因子对应的 MFE 值曲线如图 9 所示。




图 9 不同尺度因子的 MFE 值

由图 9 可知,尺度因子在 1~20 范围内,变压器不同状态的模态分量 IMF 的 MFE 值不同。因此,变压器不同状态不同尺度因子的 MFE 值可作为特征量进行识别。

随机选取变压器每种状态 100 组试验数据进行特征量提取,其中每组数据时长为 0.5 s,从而四种状态可得 400×20 型特征数据集。本文选择特征数据集的 70% (280×20) 作为训练集,剩余 30% (120×20) 作为测试集。进一步地,对变压器每种状态进行类别标记,具体如表 1 所示。

将提取到的特征数据集输入至本文所提 MVO-KELM 诊断模型中进行分类识别,得到训练和测试结果如图 10 所示。需要说明的是,所提 MVO-KELM 模型的分类结果较为稳定,不因分类次数改变而改变。

表 1 变压器不同状态类别标签

状态	标签	状态	标签
正常状态	L1	绕组铁心松动 50%	L3
绕组铁心松动 25%	L2	绕组铁心松动 70%	L4




图 10 MVO-KELM 模型分类结果

由图 10 可知,利用 MVO-KELM 对测试集进行分类的准确率达到 99.2%,证明所建模型具有较高的识别精度,可有效识别变压器绕组铁心松动故障及绕组铁心不同松动程度的故障,实现了高准确率诊断目标。

4.2 对比分析

为了验证所提方法的优越性,本文将所提 MVO-KELM 模型与已有 GWO-KELM^[19]、WOA-KELM^[20] 和 BA-KELM^[21] 模型进行对比。为了确保对比的公平性,上述对比模型的参数均选取试验结果中的最佳参数。在同一测试特征集中,本文所提模型与对比模型诊断结果的混淆矩阵如图 11 所示。

由图 11 可知, MVO-KELM、GWO-KELM、WOA-KELM 和 BA-KELM 的整体诊断准确率分别

输出类别	L1	30 25.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
	L2	0 0.0%	30 25.0%	0 0.0%	0 0.0%	100% 0.0%
	L3	0 0.0%	0 0.0%	29 24.2%	0 0.0%	100% 0.0%
	L4	0 0.0%	0 0.0%	1 0.8%	30 25.0%	96.8% 3.2%
		100% 0.0%	100% 0.0%	96.7% 3.3%	100% 0.0%	99.2% 0.8%
		↖	↘	↙	↗	
		目标类别				
(a) MVO-LELM混淆矩阵						
输出类别	L1	30 25.0%	0 0.0%	24 20.0%	0 0.0%	55.6% 44.4%
	L2	0 0.0%	30 25.0%	0 0.0%	0 0.0%	100% 0.0%
	L3	0 0.0%	0 0.0%	6 5.0%	0 0.0%	100% 0.0%
	L4	0 0.0%	0 0.0%	0 0.0%	30 25.0%	100% 0.0%
		100% 0.0%	100% 0.0%	20.0% 80.0%	100% 0.0%	80.0% 20.0%
		↖	↘	↙	↗	
		目标类别				
(b) GWO-KELM混淆矩阵						
输出类别	L1	30 25.0%	0 0.0%	14 11.7%	0 0.0%	68.2% 31.8%
	L2	0 0.0%	30 25.0%	0 0.0%	0 0.0%	100% 0.0%
	L3	0 0.0%	0 0.0%	16 13.3%	0 0.0%	100% 0.0%
	L4	0 0.0%	0 0.0%	0 0.0%	30 25.0%	100% 0.0%
		100% 0.0%	100% 0.0%	53.3% 46.7%	100% 0.0%	88.3% 11.7%
		↖	↘	↙	↗	
		目标类别				
(c) WOA-KELM混淆矩阵						
输出类别	L1	30 25.0%	0 0.0%	7 5.8%	0 0.0%	81.1% 18.9%
	L2	0 0.0%	30 25.0%	0 0.0%	0 0.0%	100% 0.0%
	L3	0 0.0%	0 0.0%	23 19.2%	0 0.0%	100% 0.0%
	L4	0 0.0%	0 0.0%	0 0.0%	30 25.0%	100% 0.0%
		100% 0.0%	100% 0.0%	76.7% 23.3%	100% 0.0%	94.2% 5.8%
		↖	↘	↙	↗	
		目标类别				
(d) BA-KELM混淆矩阵						

图 11 不同诊断模型的混淆矩阵结果

为:99.2%、80.0%、88.3%和94.2%。由此可见,本文所提模型的整体诊断准确率比其他对比模型的诊断准确率至少高出5%,证明了所提 MVO-KELM 模型在诊断准确率方面优于其他对比模型。

本文所提方法的稳定性和高准确率诊断特性能够为变压器现场检修提供指导性建议,具有一

定的实际工程应用价值。

5 结 语

本文提出了一种基于 ICEEMDAN-MFE 和 MVO-KELM 的变压器绕组铁心机械故障诊断方法,所得结论归纳如下:

(1) 改进的 ICEEMDAN 算法准确提取了变压器振动信号的状态特征,避免了额外引入白噪声导致的干扰,解决了 CEEMDAN 分解中存在虚假模态分量的问题;

(2) 利用 Pearson 相关系数法确定了最强相关性 IMF 分量,并求解了其 MFE 值,有效提高了特征数据集的准确性和有效性,解决了特征冗余问题;

(3) 提出的 MVO-KELM 诊断模型具有较高的诊断准确率,对变压器绕组铁心机械故障诊断准确率可达 99% 以上,对比比算法的准确率高出 5% 以上,实现了变压器绕组铁心机械故障的高准确率诊断目标。

【参考文献】

- [1] 张凡,李秀广,朱筱瑜,等. 计及热老化程度的变压器绕组内线圈短路承受能力评估方法[J]. 中国电机工程学报, 2022, 42(10): 3836-3846.
- [2] 周利军,周猛,李沃阳,等. 基于振荡波多特征融合的变压器绕组故障诊断方法[J]. 电力自动化设备, 2022, 42(12): 191-196+203.
- [3] 杜厚贤,刘昊,雷龙武,等. 基于振动信号多特征值的电力变压器故障检测研究[J]. 电工技术学报, 2023, 38(1): 83-94.
- [4] 汲胜昌,张凡,师愉航,等. 基于振动信号的电力变压器机械状态诊断方法研究综述[J]. 高电压技术, 2020, 46(1): 257-272.
- [5] 曹辰,徐博文,李辉. 基于振动与电抗信息的变压器绕组形变状态综合监测方法[J]. 高电压技术, 2022, 48(4): 1518-1530.
- [6] 夏存江,詹于游. 基于改进的 SENet 航空发动机振动预测[J]. 航空动力学报, 2022, 37(12): 2807-2817.
- [7] 杨毅,刘石,张楚,等. 基于振动分布特征的电力变压器绕组故障诊断[J]. 振动与冲击, 2020, 39(1): 199-208.
- [8] 侯鹏飞,马宏忠,吴金利,等. 基于混沌理论与蝗虫优化 K-means 聚类算法的电抗器铁芯和绕组松

- 动状态监测[J]. 电力自动化设备, 2020, 40(11): 181-189.
- [9] 王吉林, 孟垂懿. 基于 EEMD 的变压器振动与声音信号 IMF 峭度特征量提取方法[J]. 水电能源科学, 2019, 37(9): 183-187.
- [10] 尚海昆, 许俊彦, 李宇才, 等. CEEMDAN 在变压器振动信号提取中的应用[J]. 控制理论与应用, 2022, 39(3): 459-468.
- [11] 肖乾浩. 基于机器学习理论的机械故障诊断方法综述[J]. 现代制造工程, 2021, 490(7): 148-161.
- [12] 赵云, 宿磊, 李可, 等. 基于改进 MPE 与 KELM 的滚动轴承故障诊断[J]. 噪声与振动控制, 2022, 42(1): 125-131.
- [13] MIRJALILI S, MIRJALILI S M, HATAMLOU A. Multi-verse optimizer: a nature-inspired algorithm for global optimization. Neural Computing and Applications, 2016, 27(2): 495-513.
- [14] 管一臣, 童攀, 冯志鹏. 基于 ICEEMDAN 方法和频率解调的行星齿轮箱故障电流信号特征分析[J]. 振动与冲击, 2019, 38(24): 41-47.
- [15] 张志劲, 张翼, 蒋兴良, 等. 自然环境不同年限复合绝缘子硅橡胶材料老化特性表征方法研究[J]. 电工技术学报, 2020, 35(6): 1368-1376.
- [16] 李可, 牛园园, 宿磊, 等. 参数优化 VMD 的滚动轴承故障诊断方法[J]. 振动工程学报, 2023, 36(1): 280-287.
- [17] 郑近德, 潘海洋, 张俊, 等. 基于多变量多尺度模糊熵的行星齿轮箱故障诊断[J]. 振动与冲击, 2019, 38(6): 187-193.
- [18] 商立群, 李洪波, 侯亚东, 等. 基于 VMD-ISSA-KELM 的短期光伏发电功率预测[J]. 电力系统保护与控制, 2022, 50(21): 138-148.
- [19] 李大鹏, 周晓彦, 叶如, 等. 基于特征选择和 GWO-KELM 的鸟声识别算法[J]. 声学技术, 2022, 41(5): 782-788.
- [20] 李琨, 张久亭. 基于 TSMAAPE 与 WOA-KELM 的液压泵故障诊断[J]. 机床与液压, 2022, 50(9): 201-209.
- [21] 郭明军, 李伟光, 赵学智, 等. 基于多域特征的 BA-KELM 微型电机故障检测[J]. 振动与冲击, 2023, 42(2): 251-257.

(上接第 80 页)

- [14] 侯鹏飞, 马宏忠, 吴金利, 等. 基于混沌理论与蝗虫优化 K-means 聚类算法的电抗器铁芯和绕组松动状态监测[J]. 电力自动化设备, 2020, 40(11): 181-189.
- [15] 马宏忠, 严岩. 基于混沌理论和 GOA-K-means 算法的有载分接开关状态特征分析计算方法[J]. 电工技术学报, 2021, 36(7): 1399-1406.
- [16] 马宏忠, 侯鹏飞, 严岩, 等. 高压电抗器绕组和铁芯机械故障的混沌特性分析与特征识别[J]. 电力自动化设备, 2022, 42(5): 204-211.
- [17] 孟垚, 许力, 杨洁. 多尺度混沌时间序列在载流故障预测中的应用[J]. 电机与控制学报, 2015, 19(7): 1-7.
- [18] 李稳安. 基于混沌时间序列的复杂机械系统故障特征提取与状态预报[D]. 南京: 东南大学, 2004.

[主要栏目]

- | | | |
|--------------|-----------|-------------|
| • 控制与应用技术 | • 研究与设计 | • 故障诊断与保护 |
| • 新能源发电与局域电网 | • 新能源汽车技术 | • 发电机组及其控制 |
| • 测试技术与测控系统 | • 材料与工艺 | • 电机生产及质量管理 |
| • 电力电子变流器技术 | • 智能制造 | • 节能应用 |
| • 实用技术成果 | | |