

DOI: 10.12158/j.2096-3203.2024.03.023

# 基于特征判定系数的电力变压器振动信号故障诊断

谢丽蓉, 严磊, 吐松江·卡日, 张馨月  
(新疆大学电气工程学院, 新疆 乌鲁木齐 830047)

**摘要:** 变压器带电故障诊断对于保证电力变压器安全平稳运行具有重要的意义。针对变压器工作环境复杂且单一参数表征变压器故障类型不全面的问题, 文中提出一种基于自适应噪声完备集合经验模态分解 (complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN) 和特征熵权法 (entropy weight method, EWM) 进行故障诊断的方法。通过相关系数与峭度加权 (correlation coefficient and weighted kurtosis, CCWK) 原则筛选 CEEMDAN 分量并重构信号, 在实现剔除冗余分量的同时, 提升变压器振动信号特征的表征能力; 利用 EWM 构建特征判定系数实现单一数据诊断变压器故障类型; 通过主成分分析法减小混合域特征尺度, 采用鸡群优化算法优化支持向量机 (support vector machine, SVM) 模型进行故障诊断。对某变电站 110 kV 三相油浸式变压器进行分析, 结果表明与概率神经网络和 SVM 等变压器故障诊断方法相比, 文中方法能在提前定性故障类型的同时, 进一步提高变压器故障诊断的准确率与效率。

**关键词:** 故障诊断; 变压器振动信号; 自适应噪声完备集合经验模态分解 (CEEMDAN); 信噪比; 熵权法 (EWM); 支持向量机 (SVM); 鸡群优化算法

中图分类号: TM411

文献标志码: A

文章编号: 2096-3203(2024)03-0217-09

## 0 引言

变压器作为重要的输变电设备, 利用振动分析法对其进行故障检测, 可以减少离线时间, 同时降低事故发生的危害, 有效提高电力系统的可靠性与经济性<sup>[1-2]</sup>。

目前有许多学者对变压器内部机械结构 (铁心、绕组) 的振动特性展开研究<sup>[3-7]</sup>, 变压器器身振动信号以 100 Hz 为基频并包含高倍谐波, 到 1 000 Hz 以后谐波幅值基本衰减到 0, 可采用其中部分频率分量或频段能量特征作为判断机械结构故障的依据。但实时采集振动信号时变压器多处于复杂的工业现场环境中, 能充分反映故障信息的特征分量被淹没, 因此剔除振动信号中的无关分量与冗余成分成为分析变压器振动信号健康状态的主要研究方向。小波变换<sup>[8]</sup>、交叉小波变换<sup>[9]</sup>等方法的分解效果取决于人为选定的小波基函数, 其自适应性较差。深入研究自适应分解方法, 例如经验模态分解 (empirical modal decomposition, EMD)<sup>[10]</sup>、集合经验模态分解 (ensemble empirical mode decomposition, EEMD)<sup>[11]</sup>等方法对于非线性和非平稳信号的信号分解与特征提取已十分成熟, 但端点效应、添加的白噪声未被全部中和等问题导致重构误差较大。针对以上问题, Torres 等人提出了自适应噪声完备集合经验模态分解 (complete ensemble empirical mode

decomposition with adaptive noise, CEEMDAN)<sup>[12]</sup>, 在信号分解中加入自适应噪声, 使其具有更好的分解完备性, 且降低了重构误差。

故障诊断是根据特征的差异实现对不同故障类型的区分。信号处理后理论上会增强信号特征表征能力, 针对单一特征量对于不同故障类型的表征区分性差的问题, 可根据每个特征在故障诊断中的重要性差异赋以不同权值<sup>[13-14]</sup>, 来反映特征在特征集中的重要程度。

综上, 文中利用相关系数与峭度加权 (correlation coefficient and weighted kurtosis, CCWK) 以剔除 CEEMDAN 分解变压器振动信号中的冗余分量, 进而增强信号特征表达能力; 利用熵权法 (entropy weight method, EWM) 构建特征判定系数 (feature determination coefficients, FDC) 进行故障定性, 实现故障类型量化; 采用主成分分析法对高维混合特征集进行特征降维融合以全面表征故障类型; 由于支持向量机 (support vector machine, SVM) 参数人为选取过于主观并影响诊断精度, 文中利用鸡群优化 (chicken swarm optimization, CSO) 算法优化 SVM 模型 (下文简称 CSO-SVM) 进行变压器故障诊断。基于现场数据进行实验验证, 结果表明所提方法在运行环境复杂的工业现场仍具备良好的诊断性能。

## 1 基于 CEEMDAN-CCWK 的信号降噪分析

### 1.1 CEEMDAN 理论基础

CEEMDAN 是在 EEMD 加入正态分布的白噪声

收稿日期: 2023-12-10; 修回日期: 2024-01-22

基金项目: 国家自然科学基金资助项目 (52067021; 62163034)

的基础上,加入自适应反向白噪声,既提高了预测精度、分解完备性,又减少了计算量。CEEMDAN 方法的分解过程如下。

(1) 在原始时序信号  $x(t)$  中添加不同幅值且互为相反数的高斯白噪声  $\omega(t)$ , 即:

$$y(t) = x(t) + \varepsilon_0 \omega(t) \quad (1)$$

式中:  $y(t)$  为  $x(t)$  加入高斯白噪声以后的信号;  $\varepsilon_0$  为原始信号加入噪声的幅值。

(2) 对  $y(t)$  进行 EMD, 并对产生的  $P$  个模态分量进行加总平均得到第 1 个本征模态分量 (intrinsic mode function, IMF) IMF1 (量值为  $Y_{\text{IMF1}}(t)$ ), 并计算得到第 1 个剩余分量  $r_1(t)$ :

$$Y_{\text{IMF1}}(t) = \frac{1}{P} \sum_{w=1}^P Y_{\text{IMF1},w}(t) \quad (2)$$

$$r_1(t) = x(t) - Y_{\text{IMF1}}(t) \quad (3)$$

式中:  $Y_{\text{IMF1},w}(t)$  为  $y(t)$  进行 EMD 得到的第  $w$  个模态分量,  $w=1, 2, \dots, P$ 。

(3) 定义  $E_k(\cdot)$  为 EMD 所产生的第  $k$  个阶段的模态分量, 将剩余分量  $r_1(t)$  作为原信号重复步骤 (1)、步骤 (2), 得到 IMF2 (量值为  $Y_{\text{IMF2}}(t)$ ) 和剩余分量  $r_2(t)$ :

$$Y_{\text{IMF2}}(t) = \frac{1}{P} \sum_{z=1}^P E_1(r_1(t) + \varepsilon_1 E_1(\omega_z(t))) \quad (4)$$

$$r_2(t) = r_1(t) - Y_{\text{IMF2}}(t) \quad (5)$$

式中:  $\varepsilon_1$  为  $r_1(t)$  加入噪声的幅值;  $\omega_z(t)$  为第  $z$  个随机的高斯白噪声。

(4) 重复上述步骤, 直到获得的剩余分量为单调函数, 不能继续分解, 此时原始信号  $x(t)$  被分解为:

$$x(t) = \sum_{k=1}^N Y_{\text{IMFk}}(t) + r_k(t) \quad (6)$$

式中:  $Y_{\text{IMFk}}(t)$  为 EMD 得到的第  $k$  个 IMF,  $k=1, 2, \dots, N$ ;  $r_k(t)$  为第  $k$  个剩余分量;  $N$  为 IMF 的个数。

## 1.2 基于 CEEMDAN-CCWK 的变压器振动信号降噪处理

利用 CEEMDAN 对变压器振动信号进行处理。

(1) 首先对变压器振动信号进行 CEEMDAN, 信号分解为多个 IMF。

(2) 分别计算 IMF (量值为  $Y_{\text{IMF}}$ ) 的相关系数  $\rho$ 、峭度  $K$ 、CCWK (量值为  $M_{\text{CCWK}}$ )。

$$\rho = \frac{\text{Cov}(Y_{\text{IMF}}, x)}{\sqrt{D(Y_{\text{IMF}})} \sqrt{D(x)}} \quad (7)$$

$$K = \frac{E((Y_{\text{IMF}} - E(Y_{\text{IMF}}))^4)}{D^2(Y_{\text{IMF}})} \quad (8)$$

$$M_{\text{CCWK}} = \rho K \quad (9)$$

式中:  $x$  为变压器振动的原始信号;  $\text{Cov}(\cdot)$  为信号协方差;  $E(\cdot)$  为信号期望;  $D(\cdot)$  为信号方差。

(3) 定义 CCWK 低于阈值  $V_{\text{Thea}}$  为弱相关虚假分量与噪声, 将其剔除后重构敏感 IMF。

$$V_{\text{Thea}} = \sqrt{\left[ \sum_{k=1}^N (M_{\text{CCWKk}} - \bar{M}_{\text{CCWK}})^2 \right] / N} \quad (10)$$

式中:  $M_{\text{CCWKk}}$  为第  $k$  个 IMF 的 CCWK 值;  $\bar{M}_{\text{CCWK}}$  为 IMF 的 CCWK 均值。

(4) 提取重构信号, 通过信噪比 (signal-to-noise ratio, SNR) (量值为  $E_{\text{SNR}}$ ) 与均方根误差 (root mean square error, RMSE) (量值为  $E_{\text{RMSE}}$ )<sup>[15]</sup> 综合评价去噪效果。SNR 为降噪信号与噪声的功率之比, RMSE 为噪声功率与观测次数之比的平方根。

$$E_{\text{SNR}} = 10 \lg \left( \frac{\sum_{l=1}^T h_l^2}{\sum_{l=1}^T (h_l - x_l)^2} \right) \quad (11)$$

$$E_{\text{RMSE}} = \sqrt{\frac{1}{T} \sum_{l=1}^T (h_l - x_l)^2} \quad (12)$$

式中:  $h_l$  为第  $l$  次观测的纯净信号;  $x_l$  为第  $l$  次观测的含噪信号;  $T$  为观测次数。

## 2 基于 FDC 的变压器故障诊断

利用 EWM 构建 FDC 实现变压器故障诊断的步骤如下。

(1) 计算时频域特征  $F_C$ 、 $F_{\text{ES}}$ 、 $F_{\text{MC}}$ 、 $F_{\text{SD}}$ 。其中, 频率复杂度  $F_C$ <sup>[16-18]</sup> 越低, 能量越集中, 结构越稳定。

$$P_f = W_f^2 A_f^2 / \sum_{f=100}^{1000} W_f^2 A_f^2 \quad (13)$$

$$W_f = f / f_{\text{max}} \quad (14)$$

$$F_C = - \sum_{f=100}^{1000} P_f \ln P_f \quad (15)$$

式中:  $P_f$  为频率  $f$  的谐波比重;  $W_f$  为频率  $f$  的权重系数;  $A_f$  为频率  $f$  的幅值;  $f=100, 200, \dots, 1000$ ;  $f_{\text{max}}$  为选择的最大频率值。

能量相似度  $F_{\text{ES}}$  表示不同频段能量分布与均值能量的平均距离, 表征出现故障的可能性。

$$d_m = \sum_{f=100+f_{\text{width}}(m-1)}^{100+f_{\text{width}}m} A_f^2 \quad (16)$$

$$v_m = d_m / \sum_{m=1}^n d_m \quad (17)$$

$$\mu = \frac{1}{n} \sum_{m=1}^n v_m \quad (18)$$

$$F_{\text{ES}} = \frac{1}{n} \sum_{m=1}^n \sqrt{(v_m - \mu)^2} \quad (19)$$

式中:  $d_m$  为第  $m$  个能量带的能量;  $f_{\text{width}}$  为频带带

宽,取值为 300 Hz;  $v_m$  为第  $m$  个能量带归一标准化;  $\mu$  为平均能量;  $n$  为能量带个数。

$F_{MC}$  表示主频带位置变化;  $F_{SD}$  表示频谱分散集中程度。

$$F_{MC} = \frac{\sum_{q=1}^Q f_q^2 s(q)}{\sqrt{\sum_{q=1}^Q s(q) \sum_{q=1}^Q f_q^4 s(q)}} \quad (20)$$

$$F_{SD} = \sqrt{\frac{\sum_{q=1}^Q \left[ \left( f_q - \frac{\sum_{q=1}^Q f_q s(q)}{\sum_{q=1}^Q s(q)} \right)^2 s(q) \right]}{Q}} \quad (21)$$

式中:  $f_q$  为第  $q$  条谱线的频率值;  $s(q)$  为原始时域信号序列的频谱序列;  $Q$  为谱线数。

(2) 利用 EWM 求取特征权重。

首先,根据特征值越大越优或越小越优赋指示值  $S_{inv}$  为 1 或 0,进行不同的归一化。

$$B_{ij} = \begin{cases} \frac{A_{ij} - \min(A_j)}{\max(A_j) - \min(A_j)} & S_{inv} = 1 \\ \frac{\max(A_j) - A_{ij}}{\max(A_j) - \min(A_j)} & S_{inv} = 0 \end{cases} \quad (22)$$

式中:  $A_{ij}$  为第  $i$  个样本的第  $j$  项特征,  $i = 1, 2, \dots, c$ ,  $c$  为样本个数,  $j = 1, 2, \dots, b$ ,  $b$  为特征个数;  $A_j$  为第  $j$  个特征的特征值;  $B_{ij}$  为第  $i$  个样本的第  $j$  项特征标准化后的值。

其次,计算第  $j$  项特征在第  $i$  个样本中占该指标的比重  $W_{ij}$  为:

$$W_{ij} = B_{ij} / \sum_{i=1}^c B_{ij} \quad (23)$$

然后,计算第  $j$  项特征的信息熵  $E_j$  为:

$$E_j = -(\ln c)^{-1} \sum_{i=1}^c W_{ij} \ln W_{ij} \quad (24)$$

最后,求得第  $j$  项特征的权重  $H_j$  为:

$$H_j = (1 - E_j) / \left( b - \sum_{j=1}^b E_j \right) \quad (25)$$

(3) 构建 FDC。按照上述方法计算时频域特征  $F_C$ 、 $F_{ES}$ 、 $F_{MC}$ 、 $F_{SD}$  对应的特征权重,加权求和得到 FDC (量值为  $M_{FDC}$ ),用于定性分析变压器故障类型。

$$M_{FDC} = \sum_{j=1}^b H_j A_{ij} \quad (26)$$

### 3 基于高维混合域特征集的 CSO-SVM 变压器故障诊断

#### 3.1 CSO-SVM

SVM 分类器的原理是在特征空间建立超平面使不同类别特征集合距离最大,其优点是面临不可

分问题时,可借助各种核函数将低维特征映射到高维空间,达到准确分类的目的。SVM 分类器对于小样本、高维特征集有较高的准确性。

核函数参数  $\sigma$  与惩罚因子  $C$  共同影响 SVM 分类性能,为避免人为主观选择参数的缺陷,利用智能算法——CSO 算法<sup>[19]</sup> 对  $\sigma$ 、 $C$  智能参数寻优。CSO 算法集成了粒子群算法、遗传算法、蝙蝠算法等的优化特性,模拟鸡群等级制度和鸡群行为,能实现多子群协同搜索,并且具有优秀的自适应能力。参数寻优后可提高 SVM 故障分类的准确率与效率。

实现 CSO-SVM 参数寻优的步骤如下。

步骤 1:初始化参数。初始化鸡群规模  $F$ 、空间维数  $S$ 、最大迭代次数  $M$ 、更新代数  $G$  等参数。

步骤 2:初始化鸡群。根据鸡的适应性不同将鸡群划分为不同类型和子种群。在鸡群的等级制度中,公鸡的适应性最好,即觅食能力最强,被适应度值较低的母鸡(部分母鸡会孵化鸡蛋)和适应度值最低的小鸡(小鸡在子种群中会随机与母鸡建立亲缘关系)所包围。

步骤 3:迭代开始,先判断迭代次数  $I$  是否被  $G$  整除,是则更新等级制度;否则按照公鸡、母鸡和小鸡各自的位置更新策略更新其位置,同时计算更新位置的适应度值。

步骤 4:个体位置更新。新位置的适应度值与原位置适应度值相比,如果新位置的适应度值小就更新个体位置,否则就保持原来的位置不变。

步骤 5:达到最大迭代次数后停止迭代,并输出最优解,否则回到步骤 3,循环迭代进行搜索。

CSO-SVM 流程如图 1 所示。

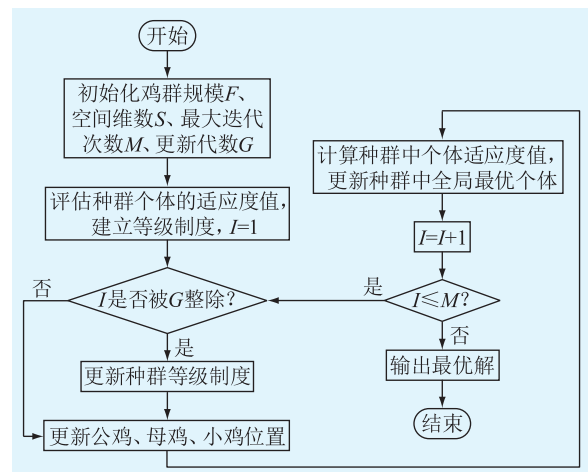


图 1 CSO-SVM 流程

Fig.1 Flow chart of CSO-SVM



### 3.2 基于 FDC 的 CSO-SVM 的变压器故障诊断

构建基于 FDC 的 CSO-SVM 的变压器机械故障状态分析与诊断综合模型,见图 2。主要步骤如下。

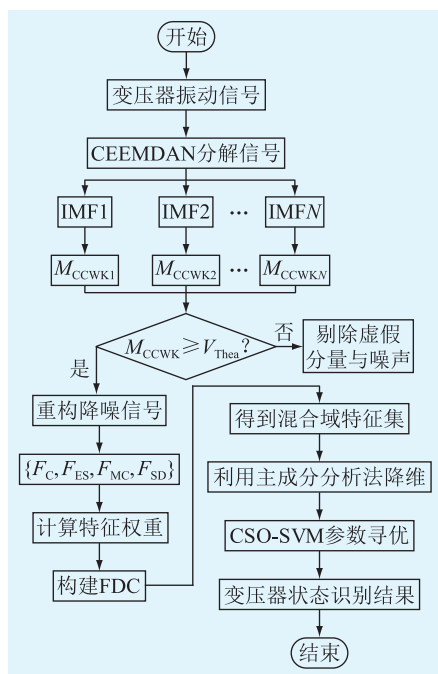


图 2 变压器故障识别流程

Fig.2 Flow chart of transformer fault identification

(1) 构建 33 维混合域特征集,其中时域包括均值、峰峰值、方差、峭度、偏度等 19 个特征,频域包括平均频率、重心频率、频率均方根等 6 个特征,及时频域特征为五层小波包分解的前 8 个节点频段的能量<sup>[20]</sup>。

(2) 利用主成分分析法降维,以累计方差贡献度不低于99.5%为判定准则,确定最优主元数量,提取该部分主成分组成新的特征集。

(3) 利用 FDC 将定性分析数据类型分为铁心故障或绕组故障,并对数据集进行标记。

(4) 利用 CSO 算法优化 SVM 核函数参数  $\sigma$  与惩罚因子  $C$ ,最终识别变压器状态为正常、铁心故障、绕组松动,对比分类的准确率、F1-Score<sup>[21]</sup>、G-mean<sup>[22]</sup>和时间,以评估分类器综合性能。

## 4 现场信号分析

### 4.1 振动信号采集

变压器机械故障模拟实验中,振动信号采集对象是新疆某变压器厂生产日期为 2007 年、型号为 SF9-40000/110 的三相油浸式电力变压器,其额定容量为 40 000 kV·A,高压侧额定电压为 110 kV,低压侧为 10.5 kV。

利用压电式加速度传感器采集模拟变压器的

不同故障类型的振动信号,采样频率设为 10 kHz。加载 100%额定电压进行空载实验,加载 100%额定电流进行负载实验。在真实振动信号在线监测的使用场景中,对变压器进行吊罩,通过调节夹件、紧固螺栓、改变铁心压紧力来设置铁心松动;通过调节绕组顶部、压紧螺母来设置绕组松动。在空载实验中测取故障类型对应铁心正常、铁心松动 50%与铁心松动 80%的振动信号,在负载实验中测取绕组正常、A 相绕组松动 40%与 C 相绕组松动 80%的振动信号。

实验六通道测量点布置在变压器油箱外壁上,避开加强筋等干扰位置,具体测点安排如图 3 所示。




图 3 传感器放置位置

Fig.3 Sensor placement

### 4.2 振动信号 CEEMDAN-CCWK 降噪处理

由于工业条件下测点 4、5、6 处的传感器安装更为便利,为分析变压器振动特性,对测点 4、5、6 展开研究。图 4 为铁心正常情况下的包络谱。在变压器的电流和电压保持不变的情况下<sup>[23]</sup>,A、C 两相振动信号的基频幅值是大于 B 相的,且 B 相受 A、C 两相振动叠加干扰,不便于区分绕组故障类型。对于大型变压器来说,C 相位于风扇端,风扇运行对故障分析有不利影响。因此,选取远离风扇端的 A 相进行故障分析,即选择测点 4 进行信号分析。




图 4 不同测点振动信号包络谱

Fig.4 Envelope spectra of vibration signals at different measurement points

理论上,变压器振动信号频段位于 0~1 000 Hz 范围内,1 000 Hz 以后振动幅值基本衰减为 0<sup>[2]</sup>。工业现场条件下实际采集铁心振动信号的时域图与频谱图如图 5 所示。根据变压器振动机理所产生的信号频率范围<sup>[24-25]</sup>,振动信号频率高于 1 000 Hz 为干扰信号,因此亟须对其进行信号处理,以便后续进行故障诊断。




图5 铁心振动信号时域波形及频谱分布

Fig.5 Normal vibration signal time-domain waveform and spectral distribution of iron core

利用 CEEMDAN 分解原始信号得到多个子信号序列,图 6 展示了分解的部分 IMF。


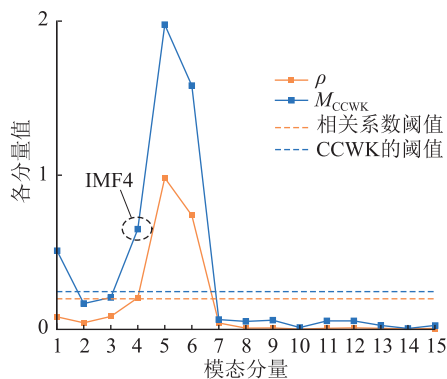


图6 CEEMDAN 分解信号得到的部分 IMF

Fig.6 Partical IMF obtained by decomposing the signal with CEEMDAN

对分解信号按照不同原则进行信号重构,按照式(10)求得分量阈值。按照相关系数原则筛选强相关分量 IMF5、IMF6,按照 CCWK 原则筛选 IMF4、IMF5、IMF6 并重构信号,如图 7 所示。

图7 各模态分量相关系数  $\rho$ 、CCWK 量值  $M_{CCWK}$ Fig.7  $\rho$  and  $M_{CCWK}$  of each modal component

将峭度作为权值赋予相关系数能够放大振动幅值较大的频段信号。对于振动信号中高频的无关分量,其相关系数极小,与峭度加权后频谱图中仍可视作 0;对于低频中的相关分量,峭度很好地放

大了频段内相关性强的频段信号振动特性。按不同重构原则重构的降噪信号的频谱如图 8 所示。




图8 不同重构原则的重构信号频谱

Fig.8 Spectrogram of reconstructed signals with different reconstruction principles

由图 8 可知,利用 CCWK 原则所得到的重构信号能够在过滤掉高频无关分量的同时更好地保留符合振动特性的振动信号。为比较相关系数、CCWK 两种重构原则的信号预处理效果,采用 SNR、RMSE 作为评价指标,即  $E_{SNR}$  越大、同时  $E_{RMSE}$  越小,表明降噪质量越高。表 1 对比了 EMD、EEMD 与 CEEMDAN 在不同重构原则下的降噪性能。

表 1 不同信号处理方法性能比较

Table 1 Performance comparison of different signal processing methods

信号处理方法	$E_{SNR}/\text{dB}$	$E_{RMSE}$
EMD-相关系数	6.340 6	0.004 2
EEMD-相关系数	7.343 5	0.003 7
CEEMDAN-相关系数	8.777 7	0.003 2
EMD-CCWK	7.343 5	0.003 7
EEMD-CCWK	8.905 6	0.003 1
CEEMDAN-CCWK	12.047 2	0.002 2

通过表 1 可以发现,分解算法 EMD、EEMD、CEEMDAN 利用相关系数原则或 CCWK 原则重构信号时,CEEMDAN-CCWK 处理后的  $E_{SNR}$  高达 12.047 2 dB,  $E_{RMSE}$  低至 0.002 2,相比于其他信号处理方法具有更好的降噪效果。变压器不同状态信号经 CEEMDAN-CCWK 处理后的频谱如图 9 所示。

由图 9 可知,经 CEEMDAN-CCWK 重构后的铁心振动主频率为 300 Hz,至 1 000 Hz 振动幅值逐渐衰减为 0;绕组松动时处理后的振动主频率 100 Hz 较绕组正常状态要高出约 1.2 倍,至 400 Hz 振动幅值逐渐衰减为 0。




图9 变压器不同状态信号降噪频谱

Fig.9 Spectrogram of signal noise reduction in different states of transformer

### 4.3 信号特征提取与构建 FDC

现场监测变压器同一状态全天的振动数据,每5 s记录一次数据。如图10所示,选取5个时刻,对比铁心正常、铁心松动50%、铁心松动80%、绕组正常、A相绕组松动40%、C相绕组松动80%6种类型的变压器故障特征矩阵。

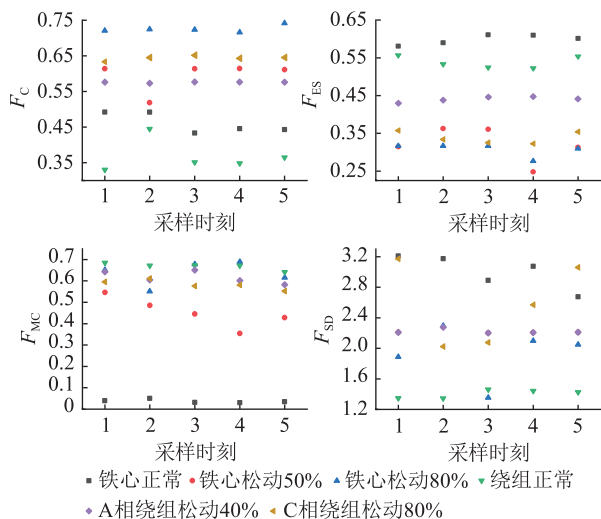


图10 不同故障类型对应特征值

Fig.10 Different fault types correspond to eigenvalues

由图10可知,变压器不同故障振动信号特征有一定区别,且不同采样时刻对应特征有一定波动,即单一特征无法高度表征故障类型。取不同故障类型各20条数据的故障特征 $\{F_C, F_{ES}, F_{MC}, F_{SD}\}$ ,采用EWM赋以铁心故障判断指示值为 $\{0, 1, 1, 0\}$ ,绕组故障判断指示值为 $\{0, 1, 0, 1\}$ ,求得铁心与绕组故障诊断权重系数如图11所示。

对不同特征按重要性差异进行加权,计算求得的FDC能够直观量化故障类型。将变压器正常状态的FDC视作标准系数,多次测量计算并取均值,求得不同状态下的FDC,如表2所示。

由表2可以看出,FDC表征故障类型整体呈现为:铁心与绕组的FDC值越接近1,故障程度越低。利用测点1验证该方法依然可行。实验证明,EWM




图11 故障评价指标特征权重

Fig.11 Fault evaluation index feature weights

表2 不同状态下的FDC值

Table 2 FDC values in different states

状态	$M_{FDC}$
C相绕组松动80%	0.783
A相绕组松动40%	0.844
变压器正常	1
铁心松动50%	1.126
铁心松动80%	1.193

结合故障特征矩阵构建的FDC可以很好地表征变压器运行状态,即可利用FDC定性分析变压器故障对象,并针对该对象进行简单的故障程度比较。

### 4.4 基于FDC的CSO-SVM故障诊断结果分析

为精确判定变压器故障类型与程度,使用CSO-SVM进行变压器机械智能故障诊断。将变压器空载铁心正常、负载绕组正常与铁心松动50%、铁心松动80%、A相绕组松动40%与C相绕组松动80%分别对应标签0—5,并对总计528组数据进行训练与测试,数据按照8:2划分训练集与测试集。通过提取时域、频域、时频域特征构建33维混合域特征集。高维混合域特征集可全面表征故障类型,但特征维数过高将很大程度降低识别效率。因此采用主成分分析法降维,按累计贡献度判定准则,得到14维最优特征集,降低数据集的相关性与冗余性,大大提升数据处理效率,增强分类器泛化性能与识别准确率。

CSO-SVM中设置种群规模为20、最大迭代次数为100。利用CSO算法对SVM中的超参数进行优化<sup>[26]</sup>,其惩罚因子 $C$ 与核函数参数 $\sigma$ 适应度变化曲线如图12所示,迭代31次达到收敛状态。

基于CSO-SVM的测试集故障识别结果如图13所示,其中绕组故障诊断错误率较高。

为提高故障诊断精度,对待检测数据集进行FDC定性分析,诊断正常、铁心故障、绕组故障3种状态。在此基础上,再次进行CSO-SVM模型智能诊断,此时模型诊断性能极佳。经FDC定性后的CSO-SVM故障识别率达到了99.24%。

表3为变压器不同状态识别方法的性能比较。




图 12 参数寻优曲线

Fig.12 Parameter tuning curves




图 13 基于 CSO-SVM 的故障识别结果

Fig.13 Fault identification results based on CSO-SVM

由表 3 可知,文中所提 CSO-SVM 方法的分类准确率、F1-Score、G-mean 都明显优于概率神经网络 (probabilistic neural networks, PNN)<sup>[27]</sup>、SVM、麻雀算法 (sparrow search algorithm, SSA) 优化 SVM (简称 SSA-SVM)<sup>[28]</sup>,且运行时间最短。

表 3 变压器不同状态识别方法性能比较

Table 3 Comparison of transformer status identification performance in different methods

识别方法	准确率/%	F1-Score	G-mean	运行时间/s
PNN	61.15	0.408		2.624
SVM	71.97	0.531	0.723	31.078
SSA-SVM	88.84	0.724	0.834	20.056
CSO-SVM	95.45	0.825	0.913	16.669
基于 FDC 的 CSO-SVM	99.24	0.967	0.952	18.037

总结得知,文中提出的 FDC 适用于无监督下诊断极少量样本状态,诊断过程更为直观,且单条数据检测较快(约 0.54 s),但不适用于数据量较大时的诊断;CSO-SVM 能够准确诊断大量变压器故障类型,准确率较 PNN、SVM、SSA-SVM 算法分别提高了 34.30%、23.48%、6.61%,且 F1-Score、G-mean 体现分类性能整体最优。经由 FDC 定性分析后,CSO-SVM 提高识别率至 99.24%,提高了 3.79%。

## 5 结论

基于变压器工作现场环境嘈杂与单一特征难以量化表征故障类型的问题,文中提出一种基于 FDC 的 CSO-SVM 变压器机械故障诊断方法,得出以下结论:

(1) CEEMDAN 对振动信号进行预处理,利用复合指标 CCWK 进行信号重构,能够有效剔除冗余分量,降低环境干扰,为提高模型故障识别准确率奠定了基础;

(2) FDC 对振动数据单一时的变压器运行状态可表征定性,提高诊断精度约 3.79%,且能减少人工成本,降低故障风险;

(3) 与传统的智能诊断方法相比,CSO-SVM 故障诊断方法准确率高达 95.45%,综合性能更好。

受限于大型变压器故障样本少、振动数据采集成本高昂问题,文中重点讨论变压器单故障识别,对于实际运行中存在的并发故障的识别会是后续研究重点。

### 参考文献:

- [1] 蔡文方,聂玲,应光耀,等. 振动分析法在变压器故障诊断及隐患治理中的应用[J]. 浙江电力,2022,41(2):53-59.  
CAI Wenfang, NIE Ling, YING Guangyao, et al. Application of vibration analysis in transformer fault diagnosis and hidden peril management[J]. Zhejiang Electric Power, 2022, 41(2): 53-59.
- [2] 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.  
JI Shengchang, ZHANG Fan, SHI Yuhang, et al. Review on vibration-based mechanical condition monitoring in power transformers[J]. High Voltage Engineering, 2020, 46(1): 257-272.
- [3] 张凡,吴书煜,徐征宇,等. 变压器绕组非线性动力学模型及多次短路冲击下的振动特征[J]. 高电压技术,2022,48(12):4882-4892.  
ZHANG Fan, WU Shuyu, XU Zhengyu, et al. Nonlinear vibration model of transformer windings and their vibration characteristics during multiple short circuits[J]. High Voltage Engineering, 2022, 48(12): 4882-4892.
- [4] 师愉航,汲胜昌,张凡,等. 变压器绕组多倍频振动机理及特性[J]. 高电压技术,2021,47(7):2536-2544.  
SHI Yuhang, JI Shengchang, ZHANG Fan, et al. Multi-frequency vibration mechanism and characteristics of transformer windings[J]. High Voltage Engineering, 2021, 47(7): 2536-2544.
- [5] 董家睿,李基民,魏铭. 谐波激励下电力变压器振动特性[J]. 高压电器,2023,59(8):35-42.  
DONG Jiarui, LI Jimin, WEI Ming. Vibration characteristics of power transformers under harmonic excitation[J]. High Voltage Apparatus, 2023, 59(8): 35-42.
- [6] 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.
- DU Houxian, LIU Hao, LEI Longwu, et al. Power transformer fault detection based on multi-eigenvalues of vibration signal [J]. Transactions of China Electrotechnical Society, 2023, 38(1):83-94.
- [7] 刘力卿,马小光,李雪,等. 变压器绕组轴向振动模型及固有振动特性影响因素研究[J]. 高压电器,2023,59(4):149-155.
- LIU Liqing, MA Xiaoguang, LI Xue, et al. Study on axial vibration model and influence factors of inherent vibration characteristics of transformer winding [J]. High Voltage Apparatus, 2023, 59(4):149-155.
- [8] 温竹鹏,陈捷,刘连华,等. 基于小波变换和优化 CNN 的风电齿轮箱故障诊断[J]. 浙江大学学报(工学版),2022,56(6):1212-1219.
- WEN Zhupeng, CHEN Jie, LIU Lianhua, et al. Fault diagnosis of wind power gearbox based on wavelet transform and improved CNN [J]. Journal of Zhejiang University (Engineering Science), 2022, 56(6):1212-1219.
- [9] 赵莉华,丰遥,谢荣斌,等. 基于交叉小波的变压器振动信号幅频特征量提取方法[J]. 高电压技术,2019,45(2):505-511.
- ZHAO Lihua, FENG Yao, XIE Rongbin, et al. Amplitude and frequency feature extraction for transformer vibration based on cross-wavelet transform [J]. High Voltage Engineering, 2019, 45(2):505-511.
- [10] HUANG N E, SHEN Z, LONG S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and nonstationary time series analysis [J]. Proceedings of the Royal Society of London Series A: Mathematical, Physical and Engineering Sciences, 1998, 454(1971):903-995.
- [11] WU Z H, HUANG N E. Ensemble empirical mode decomposition: a noise-assisted data analysis method [J]. Advances in Adaptive Data Analysis, 2009, 1(1):1-41.
- [12] ZHAO H S, XU F H, XU W Q, et al. Feature extraction method of transformer vibration based on ensemble empirical mode decomposition subband [C]//2016 IEEE International Conference on Power System Technology (POWERCON). Wollongong, NSW, Australia. IEEE, 2016:1-6.
- [13] 戴国华,戴睿,张琪瑞,等. 基于主客观赋权相结合的省级电网发展诊断分析方法与实证研究[J]. 电力系统保护与控制,2022,50(2):110-118.
- DAI Guohua, DAI Rui, ZHANG Qirui, et al. Empirical study and analysis of provincial power grid development diagnosis based on the combination of a subjective and objective weighting method [J]. Power System Protection and Control, 2022, 50(2):110-118.
- [14] 李俊杰,程婉静,梁媚,等. 基于熵权-层次分析法的中国现代煤化工行业可持续发展综合评价[J]. 化工进展,2020,39(4):1329-1338.
- LI Junjie, CHENG Wanqing, LIANG Mei, et al. Comprehensive evaluation on sustainable development of China's advanced coal to chemicals industry based on EWM-AHP [J]. Chemical Industry and Engineering Progress, 2020, 39(4):1329-1338.
- [15] 刘嘉辉,秦仙蓉,王玉龙,等. 基于双树复小波变换与样本熵的自适应降噪法[J]. 振动.测试与诊断,2022,42(2):285-291,407.
- LIU Jiahui, QIN Xianrong, WANG Yulong, et al. Adaptive denoising of monitoring signal based on dual-tree complex wavelet transform and sample entropy [J]. Journal of Vibration, Measurement & Diagnosis, 2022, 42(2):285-291, 407.
- [16] YANG H. Multiscale recurrence quantification analysis of spatial cardiac vectorcardiogram signals [J]. IEEE Transactions on Bio-Medical Engineering, 2011, 58(2):339-347.
- [17] CHEN Y, YANG H. Multiscale recurrence analysis of long-term nonlinear and nonstationary time series [J]. Chaos, Solitons & Fractals, 2012, 45(7):978-987.
- [18] 邓光源. 基于物联网的电力变压器振动监测与诊断算法及其系统软件的研究与开发 [D]. 杭州:浙江大学,2019.
- DENG Guangyuan. Algorithm and software development for power transformer vibration monitoring and diagnosing system based on IoT [D]. Hangzhou: Zhejiang University, 2019.
- [19] 张然,陈成锴,潘成胜. 基于混沌鸡群优化的无人机抗多径盲均衡算法[J]. 火力与指挥控制,2022,47(7):26-31.
- ZHANG Ran, CHEN Chengkai, PAN Chengsheng. Chaos chicken swarm optimization-based blind equalization algorithm for multipath mitigation of UAVs [J]. Fire Control & Command Control, 2022, 47(7):26-31.
- [20] 潘超,陈祥,蔡国伟,等. 基于小波包尺度-能量占比的变压器三相不平衡绕组振动特征辨识[J]. 仪器仪表学报,2020,41(4):129-137.
- PAN Chao, CHEN Xiang, CAI Guowei, et al. Identification of winding vibration characteristics of three-phase unbalanced transformer based on scale-energy ratio of wavelet packet [J]. Chinese Journal of Scientific Instrument, 2020, 41(4):129-137.
- [21] 陈维刚,张会林. 基于 RF-LightGBM 算法在风机叶片开裂故障预测中的应用[J]. 电子测量技术,2020,43(1):162-168.
- CHEN Weigang, ZHANG Huilin. Application of RF-LightGBM algorithm in early warning of fan blade cracking [J]. Electronic Measurement Technology, 2020, 43(1):162-168.
- [22] 朱敏,刘奇,刘星,等. 基于 LMKL 和 OC-ELM 的航空电子部件故障检测方法[J]. 系统工程与电子技术,2020,42(6):1424-1432.
- ZHU Min, LIU Qi, LIU Xing, et al. Fault detection method for avionics based on LMKL and OC-ELM [J]. Systems Engineering and Electronics, 2020, 42(6):1424-1432.
- [23] 赵莉华,丰遥,谢荣斌,等. 油浸式变压器铁心振动特性分析[J]. 电力系统及其自动化学报,2018,30(10):104-110.
- ZHAO Lihua, FENG Yao, XIE Rongbin, et al. Analysis of vibration characteristics for oil-immersed transformer core [J]. Proceedings of the CSU-EPSA, 2018, 30(10):104-110.
- [24] 纪炜,刘建戈,陆伟锋,等. 变压器铁心振动及分布特性研



- 究[J]. 高压电器,2023,59(1):134-141.
- JI Wei, LIU Jiange, LU Weifeng, et al. Research on vibration and distribution characteristics of transformer core[J]. High Voltage Apparatus,2023,59(1):134-141.
- [25] 郑婧,王婧岷,郭洁,等. 电力变压器铁心振动特性分析[J]. 电子测量与仪器学报,2010,24(8):763-768.
- ZHENG Jing, WANG Jingdi, GUO Jie, et al. Vibration analysis of power transformer cores[J]. Journal of Electronic Measurement and Instrument,2010,24(8):763-768.
- [26] 王志中. 基于特征参量优选与麻雀优化 XGBoost 的变压器故障诊断研究[D]. 阜新:辽宁工程技术大学,2022.
- WANG Zhizhong. Research on transformer fault diagnosis based on characteristic parameter optimization and sparrow optimization XGBoost[D]. Fuxin: Liaoning Technical University,2022.
- [27] 党建,罗燧,田录林,等. 基于优化的 VMD 融合信息熵和 FA\_PNN 的风电机组齿轮箱故障诊断[J]. 太阳能学报,2021,42(1):198-204.
- DANG Jian, LUO Yi, TIAN Lulin, et al. Fault diagnosis of wind turbine gearbox based on optimized vmd fusion information entropy and FA\_PNN[J]. Acta Energetica Solaris Sinica,2021,42(1):198-204.
- [28] 王雨虹,王志中,付华,等. 多策略改进麻雀算法与 BiLSTM 的变压器故障诊断研究[J]. 仪器仪表学报,2022,43(3):87-97.
- WANG Yuhong, WANG Zhizhong, FU Hua, et al. Research on transformer fault diagnosis based on the improved multi-strategy sparrow algorithm and BiLSTM[J]. Chinese Journal of Scientific Instrument,2022,43(3):87-97.

作者简介:



谢丽蓉

谢丽蓉(1969),女,硕士,教授,博士生导师,研究方向为控制系统优化、新能源发电、故障诊断等(E-mail:1064116595@qq.com);

严倡(1998),女,硕士,研究方向为变压器故障诊断;

吐松江·卡日(1984),男,博士,副教授,研究方向为人工智能与模式识别、电力设备状态评估。

## Power transformer vibration signal fault diagnosis based on feature determination coefficient

XIE Lirong, YAN Lyu, TUSONGJIANG · Kari, ZHANG Xinyue

(School of Electrical Engineering, Xinjiang University, Urumqi 830047, China)

**Abstract:** Transformer live fault diagnosis is of great significance to ensure the safe and stable operation of power transformers. In response to the problem of complex working environment and limited fault types characterized by a single parameter, a method based on complete ensemble empirical mode decomposition with adaptive noise (CEEMDAN) and feature entropy weights method (EWM) is proposed for fault diagnosis. The correlation coefficient weighted kurtosis (CCWK) principle is used to filter the CEEMDAN components and reconstruct the signal to achieve an improved characterisation of transformer vibration signal features while eliminating redundant components. The EWM is used to construct feature determination coefficients (FDC) to achieve a single data diagnosis of transformer fault types. The principal component analysis (PCA) is used to reduce the scale of mixed domain features and the chicken swarm optimization (CSO) algorithm is used to optimize support vector machine (SVM) model for fault diagnosis. The analysis is performed on a 110 kV three-phase oil-immersed transformer in a certain substation, and the results show that compared with other transformer fault diagnosis methods such as probabilistic neural network (PNN) and SVM, the proposed method not only provides early qualitative fault type identification but also improves the accuracy and efficiency of transformer fault diagnosis.

**Keywords:** fault diagnosis; transformer vibration signal; complete ensemble empirical mode decomposition with adaptive noise (CEEMDAN); signal-to-noise ratio; entropy weight method (EWM); support vector machine (SVM); chicken swarm optimization algorithm

(编辑 陆海霞)