

基于时变滤波经验模态分解和 SSA-LSSVM 的 变压器内部机械故障诊断方法^{*}

臧旭¹, 张甜瑾¹, 邵心悦¹, 杨嵩¹, 陈子豪¹, 吴金利²

(1. 国网江苏省电力有限公司镇江供电分公司, 江苏 镇江 212000;

2. 河海大学 能源与电气学院, 江苏 南京 211100)

摘要: 为了准确有效地识别变压器内部的潜伏性机械故障, 提出了一种基于时变滤波经验模态分解 (TVFEMD) 和麻雀搜索算法优化最小二乘支持向量机 (SSA-LSSVM) 的变压器内部机械故障诊断方法。首先, 对铁心处于不同松动状态的变压器进行振动信号采集; 其次, 利用时变滤波改进的经验模态分解 (EMD) 对所得振动信号进行分解, 以获取多个本征模态函数 (IMF) 即模态分量; 然后, 采用相关系数法计算 IMF 分量与原始振动信号的相关性, 并计算相关性最大的 IMF 分量的样本熵, 以此构建特征向量集; 最后, 以诊断准确率最高为目标函数, 利用 SSA 对 LSSVM 的正则化参数和核函数参数进行优化, 搭建 SSA-LSSVM 诊断模型, 并利用诊断模型对特征向量集进行诊断识别, 实现变压器铁心内部潜伏性机械故障的诊断。试验结果表明, 所提方法能够有效识别变压器内部潜伏性机械故障, 识别准确率达到 98% 以上, 比对比算法的识别准确率高出 5% 以上, 达到了高识别准确率的诊断效果。

关键词: 变压器内部机械故障; 时变滤波经验模态分解; 麻雀搜索优化最小二乘支持向量机; 样本熵; 故障诊断

中图分类号: TM41 文献标志码: A 文章编号: 1673-6540(2023)09-0049-08

doi: 10.12177/emca.2023.106

A Transformer Internal Mechanical Fault Diagnosis Method Based on TVFEMD and SSA-LSSVM^{*}

ZANG Xu¹, ZHANG Tianjin¹, SHAO Xinyue¹, YANG Song¹, CHEN Zihao¹, WU Jinli²

(1. State Grid Jiangsu Electric Power Co., Ltd., Zhenjiang Power Supply Branch, Zhenjiang 212000, China;

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

Abstract: A transformer internal mechanical fault diagnosis method based on time-varying filtered empirical modal decomposition (TVFEMD) and sparrow search algorithm optimized least squares support vector machine (SSA-LSSVM) is proposed to identify the internal latent mechanical faults of transformers accurately and effectively. Firstly, the vibration signals from transformers with iron cores in different loose states are collected. Secondly, the vibration signals are decomposed by the empirical mode decomposition (EMD) which was improved by time-varying filtered to obtain multiple intrinsic mode function (IMF); i. e. modal components (IMFs). Thirdly, the correlation coefficient method was used to calculate the correlation between the IMFs component and the original vibration signal, and the sample entropy of the IMF component with the highest correlation is calculated to construct the feature vector set. Finally, with the highest diagnostic accuracy as the objective function, SSA is used to optimize the regularization parameters and kernel function parameters of LSSVM, the SSA-LSSVM diagnostic model is built. The vector set is

收稿日期: 2023-04-17; 收到修改稿日期: 2023-05-31

^{*} 基金项目: 国家自然科学基金(51577050); 国网江苏省电力公司重点科技项目(J20200040)

作者简介: 臧旭(1994—), 男, 硕士, 工程师, 研究方向为电力设备故障诊断。

diagnosed and identified by using the diagnosis model, and the diagnosis of latent mechanical faults inside the transformer core is realized. The experimental results show that the proposed method can effectively identify the latent mechanical faults inside the transformers, and the identification accuracy reaches more than 98%, which is more than 5% higher than the identification accuracy of the comparison algorithm, achieving the diagnosis effect of high identification accuracy.

Key words: transformer internal mechanical fault; time-varying filtered empirical mode decomposition (TVFEMD); sparrow search algorithm optimized least squares support vector machine (SSA-LSSVM); sample entropy; fault diagnosis

0 引言

变压器作为电力系统的关键设备,对保障供电可靠性具有重要意义。然而,随着其投入运行的时间越来越长,变压器内部往往会产生铁心松动等潜伏性机械故障^[1],故障一旦累积严重,将会危及电力系统的整体安全。因此,对变压器内部的机械故障进行诊断,对防止电力系统可能发生的危害有非常重要的意义。目前,振动分析法已经被大量运用于变压器铁心或绕组等内部机械故障的检测中,成为当下的研究热点^[2-4]。

变压器振动信号是通过吸附于箱体表面的振动传感器采集来获得,该方法实施简单、操作方便,且采集的全过程不会影响变压器的运行状态。变压器铁心受磁致伸缩效应的影响产生振动,而铁心发生松动故障等缺陷时变压器的振动状态必定发生改变^[5-6],因此利用振动分析法进行变压器内部机械故障诊断是可行的。

文献[7]利用变压器振动信号频谱变化以辨别铁心与绕组的故障,指出变压器高次谐波分量主要由铁心振动产生,而基频同时受铁心与绕组振动影响,其为判别铁心和绕组等变压器主要故障奠定了理论基础。文献[8]将经验模态分解(EMD)运用于可分离变压器铁心与绕组各自的振动信号中,所得分离信号频谱与正常状态下一致,取得了一定的效果。文献[9]将集合经验模态分解(EEMD)应用于变压器振动、声音信号的模态分量峭度特征提取上,试验结果表明该方法提取出的特征量能够反映时域和频域特征,有利于变压器状态的判定。上述方法均在各自场合实现了一定效果,但是 EMD 方法本身存在模态混叠的问题,这会影响信号处理的准确性,EEMD 方法虽然引入白噪声减弱了模态混叠的严重程度,但是可能会掩盖掉原始信号的某些信息。虽然目前已

有相关改进方法,但是仍存在较多不足。文献[10]提出采用互补集合经验模态分解提取气体绝缘金属封闭输电线路(GIL)机械故障特征的方法,虽然解决了 EEMD 中白噪声遗留的问题,但仍存在分解过剩的问题。时变滤波经验模态分解(TVFEMD)是在 EMD 的基础上引入时变滤波技术的一种信号处理方法,该方法能够提高频率分离性能,解决 EMD 过程中产生的模态混叠问题。

麻雀搜索算法作为新型智能优化算法,具有出色的寻优能力,已成功应用于故障诊断、状态评估和预测等方面。文献[11]采用麻雀搜索算法优化了详尽可能性模型(ELM)的输入权值并隐藏层节点偏置,提高了油浸式变压器故障诊断模型的准确率。

综上所述,本文提出一种基于时变滤波经验模态分解和麻雀搜索算法优化最小二乘支持向量机(SSA-LSSVM)的变压器内部机械故障诊断方法,对变压器铁心不同程度的松动进行诊断识别。首先,采用 TVFEMD 对振动信号进行分解获取多个模态分量(IMF);然后,选取相关性最优的 IMF 分量,并计算其样本熵;进一步地,利用所求熵值构建特征向量集;最后,利用 SSA 优化的 LSSVM 模型实现变压器铁心内部潜伏性机械故障的诊断。试验结果表明,相较于传统的故障分类模型,所提方法能够更加准确地识别变压器内部的机械故障和不同故障程度。

1 基于 TVFEMD 的变压器振动信号特征提取

1.1 TVFEMD 基本原理

TVFEMD 算法设计时充分考虑了 EMD 方法的不足,其最大特点在于采用非均匀 B 样条近似作为时变滤波器从而完成筛选过程,同时,充分利用瞬时幅度和频率信息,自适应地设计了局部截

止频率^[12],TVFEMD 方法具体实现过程如下。

对于测得的变压器振动信号 $x(t)$, 记其对应的希尔伯特变换为 $\hat{x}(t)$ 。则瞬时幅值可表示为

$$A(t) = \sqrt{x^2(t) + \hat{x}^2(t)} \quad (1)$$

瞬时相位可表示为

$$\varphi(t) = \arctan \frac{\hat{x}(t)}{x(t)} \quad (2)$$

考虑由 N 个窄带分量组成的多分量信号可表示为

$$x(t) = \sum_{m=1}^N a_m(t) \cos[\varphi_m(t)] \quad (3)$$

式中: $a_m(t)$ 为第 m 个分量瞬时幅值; $\varphi_m(t)$ 为相位。

当 $N=2$ 时, 可得:

$$A^2(t) = a_1^2(t) + a_2^2(t) + 2a_1(t)a_2(t) \cdot \cos[\varphi_1(t) - \varphi_2(t)] \quad (4)$$

$$\begin{aligned} \varphi'(t) = & \frac{1}{A^2(t)} \{ \varphi'_1(t) [a_1^2(t) + a_1(t)a_2(t)] \cdot \\ & \cos[\varphi_1(t) - \varphi_2(t)] \} + \varphi'_2(t) \{ a_2^2(t) + \\ & a_1(t)a_2(t) \cdot \cos[\varphi_1(t) - \varphi_2(t)] \} + \\ & \frac{1}{A^2(t)} \{ a'_1(t)a_2(t) \sin[\varphi_1(t) - \varphi_2(t)] - \\ & a'_2(t)a_1(t) \sin[\varphi_1(t) - \varphi_2(t)] \} \quad (5) \end{aligned}$$

假设 $a_1(t)$ 和 $a_2(t)$ 的变化速度比 $\cos[\varphi_1(t) - \varphi_2(t)]$ 慢得多, 那么当 $\cos[\varphi_1(t) - \varphi_2(t)] = -1$ 时, $A(t)$ 取最小值。此时的关系为

$$\cos[\varphi_1(t_{\min}) - \varphi_2(t_{\min})] = -1 \quad (6)$$

将式(6)代入式(4)和式(5)中, 可得:

$$A_{\min}(t) = |a_1(t_{\min}) - a_2(t_{\min})| \quad (7)$$

$$\begin{aligned} \varphi'(t_{\min})A^2(t_{\min}) = & \varphi'_1(t_{\min})[a_1^2(t_{\min}) - a_1(t_{\min})a_2(t_{\min})] + \\ & \varphi'_2(t_{\min})[a_2^2(t_{\min}) - a_1(t_{\min})a_2(t_{\min})] \quad (8) \end{aligned}$$

又由于:

$$A'(t_{\min}) = a'_1(t_{\min}) - a'_2(t_{\min}) = 0 \quad (9)$$

通过联立式(6)~(9), 可解得 $a_1(t_{\min})$ 、 $a_2(t_{\min})$ 、 $\varphi_1(t_{\min})$ 和 $\varphi_2(t_{\min})$; 同理, 类似的方法可求得 $a_1(t_{\max})$ 、 $a_2(t_{\max})$ 、 $\varphi_1(t_{\max})$ 和 $\varphi_2(t_{\max})$ 。随后, 通过插值可以求得 $a_1(t)$ 、 $a_2(t)$ 、 $\varphi_1(t)$ 和 $\varphi_2(t)$, 但求解上述方程十分困难。因此, 利用下列方法进行替代, 具体为

$$\begin{cases} \beta_1(t_{\min}) = A(t_{\min}) = |a_1(t_{\min}) - a_2(t_{\min})| \\ \beta_2(t_{\max}) = A(t_{\max}) = a_1(t_{\max}) + a_2(t_{\max}) \end{cases} \quad (10)$$

因为 $a_1(t)$ 和 $a_2(t)$ 波动较小, 所以 $b_1(t)$ 和 $b_2(t)$ 可依次利用 $A(\{t_{\min}\})$ 和 $A(\{t_{\max}\})$ 插值得到。假设 $a_1(t) \geq a_2(t)$, 则

$$a_1(t) = [\beta_1(t) + \beta_2(t)]/2 \quad (11)$$

$$a_2(t) = [\beta_2(t) - \beta_1(t)]/2 \quad (12)$$

进一步地, 令:

$$\begin{cases} \eta_1(t) = \varphi'_1(t)[a_1^2(t) - a_1(t)a_2(t)] + \\ \quad \varphi'_2(t)[a_2^2(t) - a_1(t)a_2(t)] \\ \eta_2(t) = \varphi'_1(t)[a_1^2(t) + a_1(t)a_2(t)] + \\ \quad \varphi'_2(t)[a_2^2(t) + a_1(t)a_2(t)] \end{cases} \quad (13)$$

联合式(5), 可得:

$$\eta_1(t_{\min}) = \varphi'(t_{\min})A^2(t_{\min}) \quad (14)$$

$$\eta_2(t_{\max}) = \varphi'(t_{\max})A^2(t_{\max}) \quad (15)$$

$h_1(t)$ 和 $h_2(t)$ 可通过 $\varphi'(\{t_{\min}\})A^2(\{t_{\min}\})$ 和 $\varphi'(\{t_{\max}\})A^2(\{t_{\max}\})$ 插值得求。有如下表达式:

$$\begin{aligned} \varphi'_1(t) = & \frac{\eta_1(t)}{2a_1^2(t) - 2a_1(t)a_2(t)} + \\ & \frac{\eta_2(t)}{2a_1^2(t) + 2a_1(t)a_2(t)} \quad (16) \end{aligned}$$

$$\begin{aligned} \varphi'_2(t) = & \frac{\eta_1(t)}{2a_2^2(t) - 2a_1(t)a_2(t)} + \\ & \frac{\eta_2(t)}{2a_2^2(t) + 2a_1(t)a_2(t)} \quad (17) \end{aligned}$$

可得局部截止频率为

$$\varphi'_{\text{bis}}(t) = \frac{\varphi'_1(t) + \varphi'_2(t)}{2} = \frac{\eta_2(t) - \eta_1(t)}{4a_1(t)a_2(t)} \quad (18)$$

由此可得:

$$h(t) = \cos\left[\int \varphi'_{\text{bis}}(t) dt\right] \quad (19)$$

对 $x(t)$ 应用该 B 样条近似滤波器, 即将 $h(t)$ 极值点作为节点, 近似结果为 $m(t)$ 。该方法设置的终止条件为

$$\theta(t) = \frac{B_{\text{Loughlin}}(t)}{\varphi_{\text{avg}}(t)} \quad (20)$$

式中: $B_{\text{Loughlin}}(t)$ 为瞬时带宽; $\varphi_{\text{avg}}(t)$ 为瞬时平均频率。

当 $\theta(t) \leq \xi$ 时, $x(t)$ 即为一个 IMF 分量; 否则, 将 $x(t) - m(t)$ 重新按照上述过程进行试验直到符合条件为止。

1.2 相关系数法

相关系数可以衡量分解后的信号与原始信号的相关性,从而剔除相关性较小的信号分量。首先计算原始信号自相关函数与各 IMF 分量自相关函数的相关系数,然后确定阈值标准,选取相关性最大的 IMF 分量,从而提高特征向量建立的准确性。相关系数计算表达式如下

$$\rho_{xy} = \frac{\sum_{i=1}^n [x_i - E(x)][y_i - E(y)]}{\sqrt{\sum_{i=1}^n [x_i - E(x)]^2 [y_i - E(y)]^2}} \quad (21)$$

式中: $E(x)$ 、 $E(y)$ 为两种信号 x 、 y 的均值。

相关性最大的阈值标准求解表达式为

$$t = \frac{\rho_{\max}}{10 \cdot (\rho_{\max})^{-3}} \quad (22)$$

式中: $\rho_{\max}$ 为相关系数的最大值。

1.3 样本熵

样本熵常用于衡量系统时间序列的复杂度^[13]。通过对经 TVFEMD 后的变压器振动信号的各 IMF 分量分别计算样本熵,可定量描述每种故障程度下变压器的振动特征。计算样本熵的具体步骤如下。

(1) 将时间序列分为 $n-m+1$ 个序列:

$$X_i(t) = [x_i(t), x_{i+1}(t), \dots, x_{i+m-1}(t)] \quad (23)$$

式中: m 为维数, $1 \leq i \leq n-m+1$; n 为序列数据个数。

(2) 计算 $d_{ij} = \max |x_{i+k}(t) - x_{j+k}(t)|$, 该式表示 $X_i(t)$ 与 $X_j(t)$ 中元素距离的最大值, 其中 $0 \leq k \leq m-1$ 。

(3) 定义阈值 r , 统计 d_{ij} ($1 \leq j \leq n-m, j \neq i$) 中小于等于 r 的数目, 记作 B_i , 定义 $B_i^m(r) = \frac{1}{n-m-1}$ B_i , 计算 $\phi^m(r) = \frac{1}{n-m-1} \sum_{i=1}^{n-m} B_i^m(r)$ 。

(4) 维数为 $m+1$ 时, 重复步骤(a)~(c)。

(5) 所求样本熵可表示为

$$\text{SampEn}(m, r, n) = \ln \phi^m(r) - \ln \phi^{m+1}(r) \quad (24)$$

2 基于麻雀搜索算法优化的 LSSVM 算法

2.1 麻雀搜索算法

麻雀搜索算法(SSA)启发于麻雀觅食与逃避

捕食者的行为,是一种新型智能优化算法^[14]。下面简要介绍 SSA 的具体过程。

在麻雀群体中,每只麻雀的行为大致可分为下列情况。

- (1) 充当发现者,搜索食物;
- (2) 充当跟随者,追踪某发现者;
- (3) 侦察危险,若危险则弃食。

假设共有 N 个麻雀,每次迭代计算的过程中,选取 P 个位置最优的麻雀作为发现者,其他的 $(N-P)$ 个则作为跟随者。

在 d 维解空间中,每只麻雀位置为 $X = (x_1, x_2, \dots, x_d)$ 。每代发现者的位置更新公式为

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t \cdot \exp\left(\frac{-i}{\alpha \cdot \text{iter}_{\max}}\right), & R_2 < ST \\ X_{i,j}^t + Q, & R_2 \geq ST \end{cases} \quad (25)$$

式中: $X_{i,j}$ 为第 i 个麻雀第 j 维信息, $j=1, 2, \dots, d$; t 为当前迭代次数; $\text{iter}_{\max}$ 为最大迭代次数; $\alpha \in (0, 1]$; $R_2 \in [0, 1]$ 为安全值; $ST \in [0.5, 1]$ 为预警值; Q 为标准正态分布随机数。

每代跟随者位置更新公式为

$$X_{i,j}^{t+1} = \begin{cases} Q \cdot \exp\left(\frac{X_{w,j}^t - X_{i,j}^t}{i^2}\right), & i > N/2 \\ X_{p,j}^t + \frac{1}{d} \sum_{j=1}^d \gamma \cdot |X_{i,j}^t - X_{p,j}^t|, & \text{其他位置} \end{cases} \quad (26)$$

式中: $X_{w,j}^t$ 和 $X_{p,j}^t$ 分别为当前全局最差位置和当前全局最优位置; j 为1或-1。

每代中随机选取 10% ~ 20% 个体意识到危险,位置更新公式为

$$X_{i,j}^{t+1} = \begin{cases} X_{p,j}^t + \beta \cdot (X_{i,j}^t - X_{p,j}^t), & f_i \neq f_g \\ X_{i,j}^t + K \cdot \left(\frac{X_{i,j}^t - X_{w,j}^t}{|f_i - f_w| + \varepsilon}\right), & f_i = f_g \end{cases} \quad (27)$$

式中: β 为标准正态分布的随机数; $K \in [-1, 1]$; ε 为较小数,防止分母为零; f_i 为当前麻雀的个体适应度值; f_w 为最差位置的适应度值; f_g 为最佳位置的适应度值。

因此,SSA 寻优的步骤即先将种群分为发现者和跟随者,再根据式(27)~式(29)更新种群位置,在此基础上更新当前全局最差和最佳个体的

位置,在达到最大迭代次数前重复上述步骤,直至最后获得最佳位置。

2.2 SSA-LSSVM 诊断模型

LSSVM 是一种广泛使用的机器学习算法,主要用于模式分类识别等领域^[15-18]。该算法是传统支持向量机(SVM)的一种扩展,其将支持向量机中松弛变量的不等式约束改为等式约束,从而可以通过求解线性方程组的方式来求解 LSSVM 的值。其中,具有径向基函数(RBF)核函数的 LSSVM 的两个参数——正则化参数 c 和核函数参数 s 对 SVM 模型的性能影响很大,直接关系到最终的分类精度。因此,本文选择将 SSA 应用于 LSSVM 的 c 、 s 参数寻优中,以获得最佳的模型识别精度。采用 SVM 诊断过程中的准确率作为适应度函数可表示为

$$A_c = \frac{N_{\text{correct}}}{N_{\text{total}}} \times 100\% \quad (28)$$

式中: N_{correct} 为识别正确的样本数; N_{total} 为全部样本个数。

3 基于 TVFEMD 和 SSA-LSSVM 的变压器内部机械故障诊断模型

本文所提基于 TVFEMD 和 SSA-LSSVM 的变压器内部机械故障的诊断步骤具体如下。

(1) 采集变压器振动信号,并将振动信号数据分为训练样本数据与测试样本数据两类;

(2) 对原始变压器振动信号进行降噪处理,并利用所提 TVFEMD 方法对处理后的振动信号进行分解;

(3) 获取分解得到的模态分量;

(4) 利用相关系数法选取与原始振动信号相关性最高的 IMF,并求其样本熵值;

(5) 利用步骤(4)所得到的样本熵值构建特征量;

(6) 根据上述步骤(1)~步骤(5)分别得到训练样本与测试样本的特征向量,并将其输入 SSA-LSSVM 模型中进行识别诊断。

综上所述,所提变压器内部机械故障诊断方法的流程图如图 1 所示。

4 试验结果验证与分析

本文对一台 10 kV 变压器进行铁心松动故障




图1 故障诊断流程图

模拟试验。具体地,通过改变变压器铁心松动程度来模拟变压器内部机械状态的变化,将采集到的振动信号用于后续的故障诊断过程中。试验时将三个振动传感器置于变压器油箱顶部,分别记为测点1、测点2和测点3,具体测点位置如图2所示。需要说明的是,传感器采用型号为 1A212E 的 IEPE 型压电式加速度传感器,采样频率为 20 kHz。



图2 变压器测点布设图

在试验开始前,对变压器进行抽油、吊罩操作,通过改变铁心的压紧螺母预紧力来实现铁心松动故障过程的模拟。本试验主要模拟了正常状态、铁心松动 25% 状态和铁心松动 50% 状态这三种典型故障状态。整体试验原理示意图如图 3 所示。调压器输入 380 V 额定电压,变压器空载运

行,振动传感器采集的数据经采集仪被计算机接收。其中,采集仪的型号为 DH5922D。




图3 试验原理示意图

以测点2位置的数据为例,本文测得的变压器三种不同状态的振动信号如图4所示。




图4 变压器不同状态2号测点位置振动信号

本文进一步利用TVFEMD对上述三种变压器的振动信号分解,所得IMF分量如图5所示。需要说明的是,为了充分有效地提取振动信号特征信息,避免出现模态混叠和分解过剩的情况,本文选择模态分量个数为6。

为避免特征冗余,采用相关系数法确定分解后所得6层IMF分量与原始信号的相关性。变压器三种状态下每个IMF分量的相关系数值如表1所示。值得注意的是,表1中的状态1、状态2和状态3分别表示正常状态、铁心松动25%状态和铁心松动50%状态。

根据式(24)得到阈值标准为0.0608,由表1可知,6层IMF分量中只有IMF2与IMF3符合标准,其余分量应在特征提取时被剔除。因此,计算各状态下IMF2与IMF3的样本熵,计算结果如表2所示。




图5 TVFEMD分解图

表1 三种状态下每个IMF分量相关系数值

状态	1	2	3
IMF1	0.035 7	0.028 4	0.042 1
IMF2	0.883 2	0.875 3	0.854 8
IMF3	0.246 7	0.325 6	0.256 3
IMF4	0.001 2	0.002 3	0.001 6
IMF5	0.000 5	0.000 3	0.000 2
IMF6	0.000 8	0.000 4	0.000 1

表 2 IMF2 与 IMF3 样本熵计算结果

状态	1	2	3
IMF2 样本熵	0.092 5	0.083 2	0.129 0
IMF3 样本熵	0.247 2	0.216 7	0.278 9

由此,即构成一组特征向量,该特征向量由 IMF2 与 IMF3 的样本熵组成,将其分别输入到 LSSVM、PSO-LSSVM 和 SSA-LSSVM 模型中进行分类识别。其中,训练样本为 200 组,测试样本为 120 组。各模型的测试分类准确率如图 6 所示,其中状态 1、状态 2 和状态 3 分别表示正常状态、铁心松动 25% 状态和铁心松动 50% 状态。




图 6 不同方法的分类结果

由图 6 可知,传统 LSSVM 模型与 PSO-LSSVM 模型在识别三类变压器铁心状态特征时均出现了识别错误的情况,而 SSA-LSSVM 模型仅出现了一次识别出错。这表明本文所提方法的分类识别效果更优。

为了进一步说明本文所提方法的优越性,计

算了上述三种识别模型在识别变压器铁心松动故障时的单一诊断准确率和整体诊断准确率,其结果如图 7 所示。




图 7 三种识别模型诊断准确率的对比

由图 7 可知,文中所提基于 TVFEMD 和 SSA-LSSVM 的变压器内部机械故障诊断方法对各程度的铁心松动故障均有较高的诊断准确率,且所提算法的诊断准确率均高于其他算法。整体来看,基于 SSA-LSSVM 模型的诊断准确率达到 99.17%,而其他两种对比模型的诊断准确率分别为 90% 和 92.5%。这也表明 SSA 对 LSSVM 的参数优化效果更好,构建的故障诊断模型准确率更高,可为变压器检修策略的制定提供相应指导。

5 结 语

本文提出了一种基于 TVFEMD 和 SSA-LSSVM 的变压器内部机械故障诊断方法,得到的结论如下。

- (1) 所提 TVFEMD 特征提取方法能够准确有效地提取变压器振动信号所蕴含的状态特征,解决了传统经验模态分解中存在的模态混叠和分解过剩的问题;
- (2) 利用相关系数法确定了与原始振动信号相关性最大的 IMF 分量,有效避免了特征冗余现象,提高了所建特征向量集的有效性和准确性;
- (3) 构建的 SSA-LSSVM 诊断模型具有出色的诊断能力,对变压器内部潜伏性故障的诊断准确率达到 98% 以上,实现了高诊断准确率的诊断目标。

【参考文献】

[1] 邓祥力,朱慧,杨梅,等. 基于多状态模型的变压器绕组早期故障保护方法研究[J]. 中国电机工程学报, 2022, 42(18): 6704.

- [2] 刘天舒, 苏昊, 潘超. 交直流混杂环境下三相变压器绕组振动研究[J]. 电力系统保护与控制, 2020, 48(8): 61.
- [3] 周利军, 周祥宇, 吴振宇, 等. 变压器绕组振荡波建模及轴向移位故障分析[J]. 电力自动化设备, 2021, 41(3): 157.
- [4] 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.
- [5] 纪炜, 刘建戈, 陆伟锋, 等. 变压器铁芯振动及分布特性研究[J]. 高压电器, 2023, 59(1): 134.
- [6] 崔佳嘉, 马宏忠. 基于改进 MFCC 和 3D-CNN 的变压器铁芯松动故障声纹识别模型[J]. 电机与控制学报, 2022, 26(12): 150.
- [7] 张仕民, 丰遥. 基于振动信号的变压器铁芯与绕组故障区分方法[J]. 电测与仪表, 2021, 58(6): 16.
- [8] 谢荣斌, 张丽娟, 靳斌, 等. 基于经验模态分解的变压器振动信号盲源分离[J]. 广东电力, 2018, 31(2): 119.
- [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.
- [10] 王立宪, 马宏忠, 戴锋. GIL 机械故障诊断与预警技术研究[J]. 电机与控制应用, 2021, 48(8): 106.
- [11] 王艳, 李伟, 赵洪山, 等. 基于油中溶解气体分析的 DBN-SSAELM 变压器故障诊断方法[J]. 电力系统保护与控制, 2023, 51(4): 32.
- [12] LI H, LI Z, MO W. A time varying filter approach for empirical mode decomposition [J]. Signal Processing, 2017, 138: 146.
- [13] RICHMAN J S, MOORMAN J R. Physiological time-series analysis using approximate entropy and sample entropy [J]. American Journal of Physiology-heart and Circulatory Physiology, 2000, 278(6): 2039.
- [14] XUE J K, SHEN B. A novel swarm intelligence optimization approach: sparrow search algorithm[J]. Systems Science & Control Engineering, 2020, 8(1): 22.
- [15] 窦顺坤, 李常贤, 张丽艳. 基于奇异谱分析与 LSSVM 算法的列车无线网络控制时延预测方法[J]. 电子测量技术, 2023, 46(1): 127.
- [16] 张先起, 赵玥, 郑志文, 等. 基于 VMD-AVOA-LSSVM 模型的月降水量预测研究[J]. 水电能源科学, 2022, 40(12): 1.
- [17] 赵嘉, 谷良, 吴瑶. 基于互信息和 GWB-LSSVM 的网络攻击检测模型[J]. 电子测量技术, 2022, 45(24): 98.
- [18] 李铭, 何毅斌, 马东, 等. 基于 ICEEMDAN-MPE 和 AO-LSSVM 的滚动轴承故障诊断[J]. 电子测量技术, 2022, 45(23): 66.

[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