

基于改进 VMD 去噪和优化 ELM 方法的 变压器早期故障诊断

刘建锋, 刘梦琪, 董倩雯, 梅智联, 周 海

(上海电力大学电气工程学院, 上海 200090)

摘 要: 变压器内部漏磁场是判断变压器绕组早期故障的重要依据。实际运行中噪声会对漏磁场检测产生干扰从而影响到故障状态的判断。为此, 首先使用遗传算法以样本熵作为适应度函数来优化变分模态分解(VMD)参数, 然后将 VMD 分解后的相关模态使用小波阈值法去除残余噪声; 其次, 选择并提取降噪漏磁场信号的特征向量, 将特征向量输入到改进极限学习机(ELM)中进行训练和分类, 实现变压器绕组的早期故障诊断。仿真及动模实验表明: 该方法去噪效果良好, 能有效地还原原漏磁场信号, 最终能实现变压器绕组早期故障的准确识别。

关 键 词: 变压器早期故障; 变分模态分解; 遗传算法; 小波阈值法; 极限学习机

DOI: 10.19781/j.issn.1673-9140.2023.06.006 中图分类号: TM41 文章编号: 1673-9140(2023)06-0055-12

Transformer early fault diagnosis based on improved VMD denoising and optimized ELM method

LIU Jianfeng, LIU Mengqi, DONG Qianwen, MEI Zhicong, ZHOU Hai

(College of Electrical Engineering, Shanghai University of Electric Power, Shanghai 200090, China)

Abstract: The internal leakage magnetic field of transformer is an important criterion for determining the early fault of transformer winding. In actual operation, noise can interfere with the detection of the leakage magnetic field, thereby affecting the judgment of the fault status. Therefore, firstly, genetic algorithms are used with sample entropy as the fitness function to optimize the parameters of variational mode decomposition (VMD). Subsequently, the relevant modes obtained from VMD are processed using wavelet thresholding to eliminate residual noise. Next, feature vectors are selected and extracted from the denoised leakage magnetic field signals. These feature vectors are then input into an improved extreme learning machine (ELM) for training and classification, achieving early fault diagnosis of transformer windings. The results of simulation and dynamic experiment show that this method exhibits a good denoising performance, effectively restoring the original leakage magnetic field signal. Ultimately, it enables accurate identification of early faults in transformer windings.

Keywords: transformer early fault; variational mode decomposition (VMD); genetic algorithm; wavelet threshold method; extreme learning machine

收稿日期: 2022-09-26; 修回日期: 2022-03-24

基金项目: 国家自然科学基金(61873159)

通信作者: 刘梦琪(1998—), 女, 硕士研究生, 主要从事电力系统继电保护与控制的研究; E-mail: 1357169497@qq.com

电力变压器在电力系统起着关键性作用,在运行过程中绕组变形以及匝间短路等早期轻微故障不易被发现,最终可能演变为重大事故^[1]。传统的差动保护门槛值整定较高,不能反应轻微匝间故障。目前的变压器故障检测主要有离线^[2]和在线监测^[3-4]2种方法,离线检测法比如短路电抗法、低压脉冲法及频响分析法都不能对变压器故障进行实时检测^[5],而且离线检测受检测周期限制,难以及时发现故障;在线监测方法中振动信号法^[6]易受外界环境影响,参数辨识法^[7]只能识别较为严重的变形,油色谱分析^[8]容易对轻微故障漏检。这些方法都无法有效识别轻微的绕组故障,考虑绕组发生轻微变形、匝间短路会引起变压器绕组漏磁场分布的改变,故可以通过检测变压器内部漏磁场的变化来诊断早期故障。

在绕组变形和匝间短路时,文献[9-11]提到变压器漏磁能够有效地反应变压器的状态,但这些分析是处于理想状态下,并未考虑信号存在干扰的情况。现场测定的漏磁场信号往往混杂着许多噪声信号,主要包括窄带周期和白噪声信号^[12-13]。因此,对现场采集的漏磁场信号进行有效的处理,进而提取真实的漏磁场变化,成为该诊断方法的关键因素。文献[14]采用小波去噪对信号进行处理,虽可以很好地去除白噪声,但存在阈值、分解层数等难确定的问题;文献[15]采用经验模式分解(empirical mode decomposition, EMD)对信号进行预处理,但这种方法容易出现模式混合,原信号有效分量被去除;文献[16]采用集合经验模式分解(ensemble empirical mode decomposition, EEMD),此方法虽然解决了模式混合问题,但迭代次数较多、用时较长。

变分模态分解(variational mode decomposition, VMD)是一种非递归信号分解方法,可以实现精确的信号分离。然而,VMD算法的分解参数需要根据特征来设置,选择不当便会造成过分解或欠分解。本文采用遗传算法(genetic algorithm, GA)对VMD参数进行优化,并将VMD分解与小波阈值的优点相结合,对混叠噪声的漏磁场信号进行去噪处理,再根据改进的分类算法实现绕组故障的早期故障分类诊断。

常用故障分类算法如反向传播神经网络(back propagation neural network, BPNN)、支持向量机(support vector machine, SVM)等可能涉及过多的处理数据规模、较高的计算复杂度,分类效率和速度均较低,这些算法很难满足当前应用的需要^[17-18]。本文将改进的极限学习机(extreme learning machine, ELM)作为变压器早期故障的分类器,此方法可以优化输入层到隐藏层的连接权重和隐藏层的阈值,不仅能减少误差迭代计算的时间,而且可提高故障识别的准确率。

1 基于改进VMD和小波阈值去噪方法

1.1 变分模态分解基本原理

假定 $f(t)$ 为变压器绕组早期故障时测量到的漏磁场信号,VMD算法是将 $f(t)$ 分解为 k 个中心频率为 ω_k 离散子信号,称为本征模态分量(intrinsic mode function, IMF)。约束变分模型构造如下:

$$\begin{cases} \min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right)^* u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \\ \text{s.t.} \quad \sum_{k=1}^K u_k = f(t) \end{cases} \quad (1)$$

式中, u_k 为由VMD分解的第 k 个模态分量; $\delta(t)$ 为单位脉冲函数; ∂_t 为相对于时间序列 t 的梯度。

为求解式(1),引入二次惩罚系数 α 以及拉格朗日乘子 $\lambda(t)$,将有约束问题转化为无约束变分问题。扩展的拉格朗日表示如下:

$$\begin{aligned} L(\{u_k\}, \{\omega_k\}, \lambda) = & \alpha \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right)^* u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \\ & \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_k u_k(t) \right\rangle \end{aligned} \quad (2)$$

采用交替方向乘子法^[19]求解方程(2)的鞍点,从而得到原始极小化问题式(1)的解,具体如下:

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \hat{\lambda}(\omega)/2}{1 + 2\alpha(\omega - \omega_k)^2} \quad (3)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k(\omega)|^2 d\omega} \quad (4)$$

式(3)、(4)中, $\hat{f}(\omega)$ 为信号频谱; $\hat{u}_k(\omega)$ 为模式频谱; n 为迭代次数。

更新拉格朗日乘数公式为

$$\hat{\lambda}^{n+1}(\omega) = \hat{\lambda}^n(\omega) + \tau \left(\hat{f}(\omega) - \sum_k \hat{u}_k^{n+1}(\omega) \right) \quad (5)$$

在求解变分模型的迭代过程中,不断更新每个IMF分量的中心频率和带宽,直到满足迭代停止条件,即

$$\sum_k \frac{\|\hat{u}_k^{n+1} - \hat{u}_k^n\|_2^2}{\|\hat{u}_k^n\|_2^2} < \varepsilon \quad (6)$$

1.2 基于GA的VMD参数确定

根据VMD理论,分解次数 k 和二次惩罚 α 对分解结果有很大影响,因此,这2个参数的确定是提高VMD性能的关键。本文采用GA来优化这2个参数。

GA是一种随机搜索优化方法,在不确定规则时便可自适应得到最优搜索空间,并自动调整搜索方向。GA首先对要优化的参数进行编码以形成串联总体;然后根据适应度函数,选择、交叉和变异筛选个体,通过反复迭代,形成更适应新环境的新编码串;最后选择适应度最好的个体,再经过解码得到最优解^[20]。

本文以最小样本熵为适应度函数在每次迭代中计算。样本熵可以反映时间序列的复杂性,时间序列越简单样本熵的值越小,因此,本文将样本熵作为改进算法的适应度函数。将测量到的漏磁场信号组成一个 N 维时间序列 $x(1), x(2), \dots, x(N)$, 将其构造为 m 维向量 $X(1), X(2), \dots, X(N-m+1)$, 其中 $X(i) = \{x(i), x(i+1), \dots, x(i+m-1)\}$, $i = 1, 2, \dots, N-m+1$ 。定义 $X(i)$ 与 $X(j)$ 之间的距离为

$$d[X(i), X(j)] = \max_{k=0,1,\dots,m-1} |x(i+k) - x(j+k)| \quad (7)$$

取两者元素差值的最大值。对于给定的 $X(i)$, 统计 $X(i)$ 与 $X(j)$ 之间的距离小于等于 r 的数目 B_i , r 为 $0.1\sigma \sim 0.25\sigma$ (σ 是时间序列的标准差)。

定义:

$$B^m(r) = \frac{1}{N-m} \sum_{i=1}^{N-m} B_i^m(r) \quad (8)$$

$$B_i^m(r) = \frac{B_i}{N-m-1}$$

最终得到样本熵定义式:

$$S_{\text{samp}}(m, r) = -\ln \left[\frac{B^{m+1}(r)}{B^m(r)} \right] \quad (9)$$

1.3 小波阈值去噪

经过参数优化的VMD和相关模式的识别,虽然能去除高斯白噪声,但仍有部分窄带周期干扰未与变压器磁场信号分离干净,为了解决这一问题,利用小波去噪方法处理剩余噪声。

改进VMD与小波阈值法结合方法的去噪结构如图1所示。

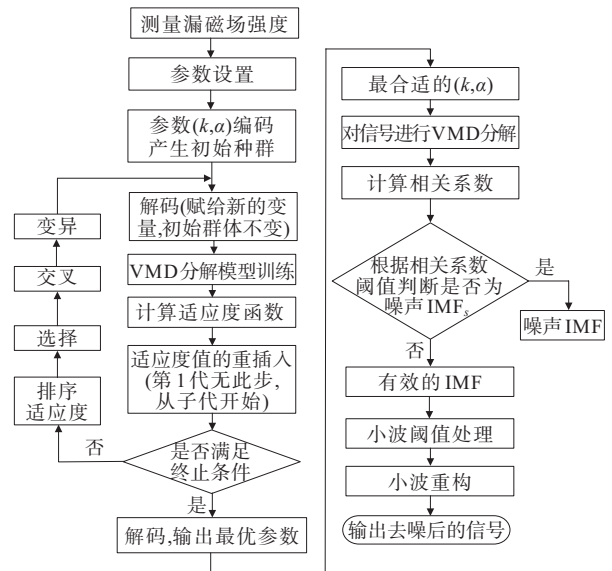


图1 改进VMD与小波阈值法去噪结构

Figure 1 Structure of improved VMD and wavelet threshold denoising

小波阈值法的去噪效果取决于阈值函数和阈值的选择。本文使用软阈值函数,定义软阈值:

$$\omega'_{j,k} = \begin{cases} \text{sgn}(\omega_{j,k})(|\omega_{j,k}| - \lambda), & |\omega_{j,k}| \geq \lambda \\ 0, & |\omega_{j,k}| < \lambda \end{cases} \quad (10)$$

式中, λ 为门限阈值; $\omega_{j,k}$ 为测试信号小波系数; $\omega'_{j,k}$ 为估计后的小波系数; j 为分解尺度。

本文中 λ 使用固定阈值,其定义如下:

$$\lambda = \sigma \sqrt{2 \ln N} \quad (11)$$

$$\sigma = \frac{\text{median}(|\omega_{1,k}|)}{0.6475}$$

式中, N 为采样点数; $\omega_{1,k}$ 为第1层的高频系数; σ 为估计噪声标准差。

2 基于ELM的变压器故障诊断方法

2.1 ELM算法

通过改进VMD与小波阈值结合方法对测量到的漏磁场信号进行降噪后,提取信号的故障特征值,然后利用ELM算法进行故障分类。ELM算法建立在单隐层前馈神经网络的基本模型之上,结构如图2所示,输入层到隐藏层的输入权重 w_i 和隐藏层的第 i 个节点偏差 b_i 是随机给定的,只需计算隐藏层节点对输出层的输出权重 β_i 。




图2 ELM结构

Figure 2 Structure of ELM

训练过程:假设有一个带标签的变压器早期故障训练样本集 $(x_i, t_i), i=1, 2, \dots, N$,其中, $x_i = [x_{i1}, x_{i2}, \dots, x_{im}]^T \in \mathbb{R}^n$ 表示样本特征; $t_i = [t_{i1}, t_{i2}, \dots, t_{im}]^T \in \mathbb{R}^m$ 表示第 m 类中第 i 个样本的标签, $t_{ij} \in \{0, 1\}, j=1, 2, \dots, m$,图2中显示有 L 个隐藏节点($L \leq N$)。数学模型为

$$t_j = \sum_{i=1}^L \beta_i g(w_i, b_i, x_i) = \sum_{i=1}^L \beta_i h(x_i) \quad (12)$$

其中, $g(w_i, b_i, x_i)$ 表示隐藏层中第 i 个节点的激活功能以及连接到输出层的方式。式(12)可简化为

$$H\beta = T \quad (13)$$

$$H = \begin{bmatrix} g(w_1, b_1, x_1) & \cdots & g(w_L, b_L, x_1) \\ \vdots & \ddots & \vdots \\ g(w_1, b_1, x_N) & \cdots & g(w_L, b_L, x_N) \end{bmatrix}_{N \times L}$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_L^T \end{bmatrix}_{L \times m}, T = \begin{bmatrix} t_1^T \\ \vdots \\ t_N^T \end{bmatrix}_{N \times m}$$

其中, H 为隐藏层输出矩阵。

式(13)参数可以转换成最小二乘解计算,即

$\min \|H\beta - T\|$,通过计算取得的最小二乘解为

$$\beta = H^+ T = (H^T H)^{-1} H^T T \quad (14)$$

式中, H^+ 为 H 矩阵的M-P广义逆。

完成训练过程后利用得到输出权重矩阵 β 在测试数据集上进行测试,最终得到输出矩阵,比较其最大值所在位置与样本标签中的位置是否一致,从而得知该测试结果是否为其最初的故障模式。

2.2 基于GA优化的ELM算法

虽然与BP神经网络相比,ELM具有学习速度快、泛化能力强以及不易陷入局部最优等优点,但是由于ELM初始化过程中在隐藏层中随机生成输入权重 w_i 和阈值 b_i ,隐层神经元几乎没有调节能力。因此,本文采用GA优化 w_i, b_i ,建立最佳结构模型,然后建立GA-ELM神经网络,提高综合算法的鲁棒性和准确性。对降噪后的漏磁场信号提取特征量,将样本分为测试集和训练集,分别做归一化处理,使用GA-ELM分类,该算法的具体流程如图3所示。

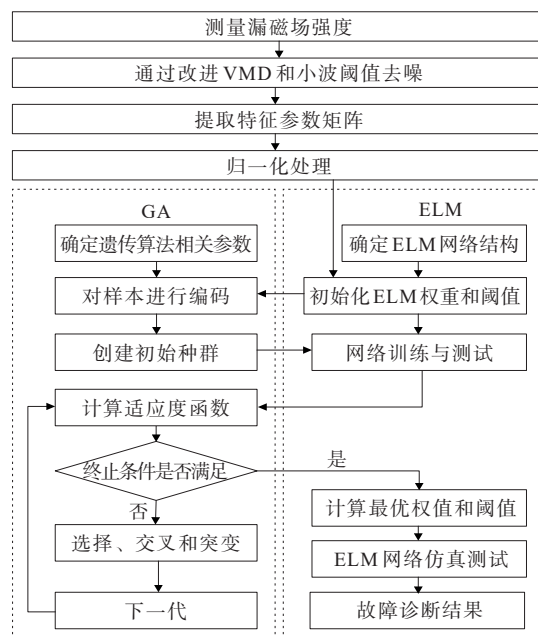


图3 基于GA-ELM的变压器故障诊断的流程

Figure 3 Flowchart of transformer fault diagnosis based on GA-ELM

3 变压器故障模型

3.1 模型的建立

基于ANSYS有限元仿真软件搭建三相三柱式

和芯式变压器模型,然后将变压器模型与外电路耦合搭建仿真模型,如图 4 所示。变压器模型的具体参数如表 1、2 所示。通过有限元计算所得到的漏磁感应强度信号与实际信号一致,将其直接用于改进 VMD 去噪仿真验证以及故障诊断仿真实验中。

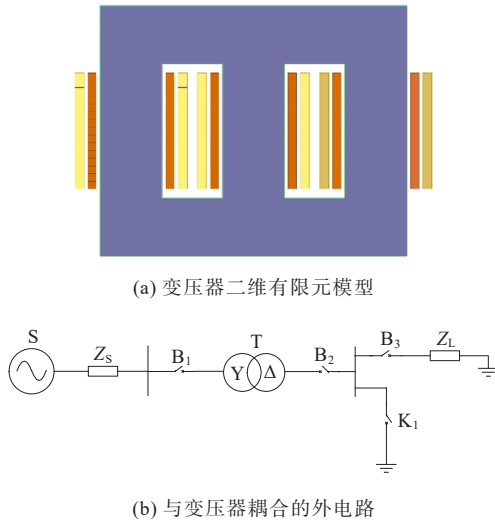


图 4 变压器的有限元模型与外电路
Figure 4 Finite element model and external circuit of transformer

表 1 变压器主要电气参数

Table 1 Main electrical parameters of transformer

额定容量/ (kV·A)	额定 电压/kV	额定 电流/A	空载 电流/%	高压绕组 电阻/ Ω
40 000	110/10.5	209/2 199	1.10	0.49
联结组别	额定 频率/Hz	短路电压 百分比/%	空载 损耗/kW	低压绕组 电阻/ Ω
YNd11	50	11.13	20.45	0.011

表 2 变压器主要结构参数

Table 2 Main structural parameters of transformer

铁芯 直径/mm	铁芯 窗高/mm	铁芯 材料	油箱 高度/mm	油箱 长度/mm
600	1 340	30Q130H	2 632	3 781
油箱 宽度/mm	上下轭 高度/mm	心柱 间距/mm	高压绕组 高度/mm	高压绕 组匝数
1 559	550	1 150	1 167	674
高压绕组内、 外径/mm	低压绕组内、 外径/mm	低压绕组 高度/mm	低压绕 组匝数	
440.5/526.5	326.5/405.5	1 167	107	

模型中将故障相绕组分为三段,选其中一段为发生匝间短路的部分,然后改变其位置,同时利用外电路的开关控制电路将所选位置进行短路操作,

以仿真绕组不同位置的匝间短路。通过改变模型中变压器绕组长度进行绕组变形仿真。

实际运行中由于绕组发生匝间短路现象以及变形模式较多且复杂,无法考虑所有故障情况,因此,本文以高压绕组故障为例,对匝间短路只考虑 3 种短路位置,对绕组变形只考虑轴向变形情况。利用建立的有限元模型,分别仿真绕组上、中、下段匝间短路(T_1 、 T_2 、 T_3)以及绕组首、末、两端压缩变形(T_4 、 T_5 、 T_6)。按照短路匝数选取短路比例,本文仿真短路程度为 0.297%~1.330%,即 2~9 匝共 8 种情况,分别考虑绕组首、末以及两端压缩变形程度为 1%~25% 的 25 种情况。

3.2 变压器绕组故障漏磁场分布特性分析

在对变压器磁场求解计算时,应用有限元法以磁矢位 A 为中间量,使用迭代法对求解区域进行解析计算,可解出各节点磁矢量值 A 。由 $B = \nabla \times A$ 解得求解区域内相应位置对应的值为

$$B = \sqrt{\left(\frac{\partial A}{\partial x}\right)^2 + \left(\frac{\partial A}{\partial y}\right)^2} \quad (15)$$

在高压绕组外侧附近取一条路径 CD ,观察此路径上不同时间下的漏磁分布。考虑动模试验光纤传感器的安装,本文最终选定 CD 上 3 个测点,用以观察磁感应强度随时间变化的情况(以下分析以测点 2 为例)。测量路径及测量点分布如图 5 所示。




图 5 测量路径及测量点分布

Figure 5 Measurement path and point distribution

不同匝间短路和绕组变形程度下测点 2 的磁场曲线如图 6 所示,与正常运行和绕组变形不同,发生绕组匝间短路时漏磁场波形会突变,强度突然增大,正常运行时的曲线相对于匝间短路近乎一条直线。同时,随着短路比例增大磁场曲线幅值也明显增大,而绕组变形时漏磁场幅值相比正常运行时会有所增加,但是波形不会有突变。随着变形比例的增大波形幅值增加。以 C 点为起点沿着 CD 的漏磁场分

布如图7所示;不同工况下CD上漏磁场分布情况如表3所示,包括漏磁场在CD上的峰值和分布特征。




图6 不同匝间短路、绕组变形程度下测点2的磁场曲线
Figure 6 Magnetic field curves of measuring point 2 under different of inter-turn short circuits and winding deformation




图7 路径CD的磁感应强度分布
Figure 7 Magnetic induction intensity distribution of path CD

表3 不同工况下路径CD上的漏磁场分布对比
Table 3 The comparison of magnetic leakage field distribution of path CD under different working conditions

工况		漏磁场分布	
正常运行		对称,峰值35.53 mT	
上段	2匝	峰值1.724 3 T	单峰突变 不对称
	4匝	峰值2.339 5 T	
	6匝	峰值2.706 6 T	
	8匝	峰值2.965 5 T	
匝间 短路	2匝	峰值2.030 4 T	单峰突变 对称
	4匝	峰值4.019 6 T	
	6匝	峰值4.171 8 T	
	8匝	峰值4.434 9 T	
中段	2匝	峰值1.927 0 T	单峰突变 不对称
	4匝	峰值2.808 3 T	
	6匝	峰值3.164 8 T	
	8匝	峰值3.251 0 T	
下段	5%	峰值48.946 6 mT	不突变 不对称
	10%	峰值63.701 6 mT	
	15%	峰值77.282 0 mT	
	20%	峰值86.392 7 mT	
单端	5%	峰值48.848 3 mT	不突变 不对称
	10%	峰值60.986 6 mT	
	15%	峰值76.895 4 mT	
	20%	峰值85.240 0 mT	
双端	5%	峰值41.704 8 mT	不突变 对称
	10%	峰值48.887 7 mT	
	15%	峰值57.295 8 mT	
	20%	峰值62.145 1 mT	

由图7、表3可以得到以下结论:

1) 发生匝间短路时轴向上漏磁在匝间短路位置出现一个突变波峰,且峰值很大;随着短路位置的变化,波峰的位置也会随之改变,同一短路程度下曲线波峰的大小未发生明显变化;

2) 当匝间短路位置处于绕组中部以及绕组发生双端压缩变形时,漏磁的轴向分布依然具有对称性;当匝间短路位置处于绕组上下部以及发生绕组首端、末端压缩变形时,绕组轴向漏磁不具有对称性。

3.3 故障特征提取

根据文3.2对绕组故障时变压器漏磁场分布变化规律的分析,可知变压器绕组状态可以通过分布情况进行有效反映。因此,本文采用漏磁感应强度作为特征量,采用测量变压器内部漏磁场的方法诊断变压器早期故障。根据分析所得结论,选取4种故障特征。

1) 相关系数。相关系数表达式为

$$\rho = \frac{\left| \sum_t x(t)y(t) \right|}{\sqrt{\sum_t x^2(t) \sum_t y^2(t)}} \quad (16)$$

采用相关系数衡量故障时的磁场信号与正常时信号之间的相关度。从文 3.2 分析可知,绕组匝间短路工况下磁场波形会有突变,而绕组变形时只是波形的幅值有一定的增大,其磁场信号与正常时的信号仍有较高的相关性。因此,绕组变形大于匝间短路时所测信号与正常运行时信号的相关度。 ρ 的阈值 ρ_{set} 选取匝间短路所有情况下的相关系数最大值,当 $\rho > \rho_{set}$ 时,则判定绕组为绕组变形,反之为绕组匝间短路。

2) 不对称度。

当绕组正常运行、中部匝间短路以及双端变形时,磁场强度沿直线的分布是具有对称性的,因此,不对称度 η 是针对磁场沿直线分布的对称性而提出的指标,通过 η 可区分这 3 种情况。

$$\eta = \frac{\sum_n |B(x_1) - B(x_3)|}{\sum_n |B(x_1) + B(x_3)|} \quad (17)$$

式中, $B(x_1)$ 、 $B(x_3)$ 分别为 1、3 号测点的磁感应强度; n 为采样点数。

由式(17)可知, η 为正数, 所得结果越大表示磁场的分布越不对称。绕组正常、中部匝间短路及双端变形时 η 很小, 说明磁场分布对称性很好, 与理论分析一致。 η 的阈值分 2 种情况来选取: 当绕组匝间短路时, 选取匝间短路位置在中部时的最大不对称度, 并考虑仿真误差和一定裕度情况, η_{set1} 取 0.1, $\eta > \eta_{set1}$ 时匝间短路位置则是在上部或下部; 当绕组变形时, 选取绕组双端变形时的最大不对称度, 并考虑仿真误差和一定裕度情况, η_{set2} 取 0.02, $\eta > \eta_{set2}$ 则是绕组首端或末端压缩变形。

3) 分布差异度。

当绕组上端故障时, 1 号大于 3 号测点磁感应强度与正常时的差值; 当绕组下端故障时, 与之相反。为确定变压器绕组故障发生在上端或下端, 定义分布差异度为

$$F = \sum_n |\Delta B(x_1)| - \sum_n |\Delta B(x_3)| \quad (18)$$

式中, $\sum_n |\Delta B(x_1)|$ 、 $\sum_n |\Delta B(x_3)|$ 分别为 1、3 号测点所包含的 n 个采样点上故障、正常情况下数据的差值取绝对值后的求和。 $F > 0$ 则表示故障发生在绕组上部分, 反之故障则发生在绕组下部分。

4) 欧氏距离。

将绕组正常时所测得 n 个采样点上的磁场强度构成一个向量 B_0 , 绕组故障后的磁场强度记作 B_j 。计算 B_0 和 B_j 的差值确定早期故障是否发生, 同时通过差值判断故障严重程度。计算向量之间差异性的算法包括欧氏距离、曼哈顿距离等。由于计算向量独立性算法不适合比较故障前、后磁场强度, 故本文选择欧氏距离, 计算公式如下:

$$D_j(x_i) = \text{dist}(B_0, B_j) = \sqrt{\sum_n [b_0(x_i) - b_j(x_i)]^2}, i = 1, 2, 3 \quad (19)$$

式中, $B_0 = (b_{01}, b_{02}, \dots, b_{0n})$; $B_j = (b_{j1}, b_{j2}, \dots, b_{jn})$; n 为采样点数据; i 为测点编号。

$$D_j = \max [D_j(x_1), D_j(x_2), D_j(x_3)] \quad (20)$$

式(20)即为在 1、2、3 号测点所计算出的结果中取最大值作为情况 $T_j (j = 1, 2, \dots, 6)$ 的欧式距离。

D 的阈值 D_{set} 取所有故障情况下欧氏距离的最小值, 并考虑仿真误差和一定裕度。当 $D_j > D_{set}$ 时, 说明绕组发生故障, 需进行故障分类及故障程度判定。

基于以上 4 种故障特征, 变压器早期故障分类流程如图 8 所示。




图 8 基于磁场分布特征的变压器早期故障分类流程

Figure 8 Flowchart of transformer early fault classification based on magnetic field distribution characteristics

4 仿真及动模验证

4.1 变压器漏磁场信号去噪


将ANSYS仿真所得到的漏磁感应强度信号作为原信号 $f(t)$ 用于模拟变压器实际运行时所测的信号,该信号是处于理想状态下的,而在变压器实际运行时存在很多电磁干扰,大部分来自高频保护信号、载波通信产生的窄带周期干扰以及继电保护信号线路耦合、变压器绕组热噪声等产生的高斯白噪声^[21]。因此,在使用改进VMD方法进行降噪仿真时,需要在原信号 $f(t)$ 上叠加以上2种干扰来模拟变压器现场测量时受到干扰的情况。

本文采用Matlab2020b仿真软件对变压器漏磁场信号去噪进行仿真,使用多个正弦波叠加而成的信号表示窄带周期干扰 $p(t)$,即


$$p(t) = A_i \sum_{i=1}^n \sin(2\pi f_i t) \quad (21)$$

设置中心频率分别为150、347、557 kHz以及1 MHz的窄带周期干扰,中心频率为557 kHz的信号幅值为原幅值的5%,其他3个信号的幅值均为原幅值的10%,再加入信噪比为15 dB的高斯白噪声 $n(t)$,最终与原始信号组成模拟现场的含噪漏磁场信号 $s(t) = f(t) + p(t) + n(t)$ 。

设置采样频率为10 kHz, t_0 取0.02 s,仿真时间设为0.14 s,采样点数为1 400;以A相的2号测点所测磁感应强度为例,验证改进VMD算法去噪的有效性;通过GA以样本熵作为适应度函数,计算VMD的分解模态数和惩罚因子,GA中设置交叉概率为0.8,变异概率为0.2,最大迭代次数为10;最后优化得到VMD的分解模态数 $k=5$,二次惩罚为1 452。将参数设定完毕后,通过VMD分解计算各分量与原信号相关系数,筛选出含噪分量。采用sym8小波对含噪分量进行4层分解,并通过软阈值处理,最终得到降噪后的信号,如图9(c)所示。通过计算,含噪信号的信噪比为13.473 2 dB,经本文方法降噪后信噪比为28.216 9 dB。使用EMD、EEMD及传统小波阈值法降噪后的信号如图10所示,可以看出仍残留部分噪声。



(a) VMD分解后的模态



(b) 加噪后信号

(c) 本文方法去噪后的信号

图9 A相测点2磁感应强度信号

Figure 9 Magnetic induction intensity signal at measurement point 2 of phase A




图10 EMD、EEMD及传统小波阈值法去噪信号

Figure 10 Denoising signal by EMD, EEMD, and wavelet threshold method

引入信噪比、均方误差及波形相似系数来评价信号的降噪效果,计算后指标如表4所示,可以看出,本文去噪方法所得信号的信噪比比其他方法

高,均方误差要小很多,与原信号的波形相似系数比其他方法高。说明本文方法相对其他去噪方法误差更小、结果更精确,所得结果更还原原信号,此算法在去除 2 类叠加干扰方面是有效的,能为后续故障信号诊断提供较理想的数据。

表 4 不同去噪方法的去噪效果对比

Table 4 Comparison of denoising effect of different methods

去噪方法	信噪比/dB	均方误差	波形相似系数
EMD	4.306 56	1.049 1	0.807 4
EEMD	12.373 40	0.411 6	0.972 7
小波阈值法	26.459 60	0.081 3	0.987 2
本文方法	28.216 90	0.066 4	0.999 3

4.2 变压器早期故障诊断

将含噪漏磁场信号经过以上降噪处理后,提取相关系数、不对称度及分布差异度 3 个特征值,再采用 GA-ELM 算法将其进行分类,并通过欧氏距离判断各种故障的严重程度。

1) 样本数据选取。

由文 3.1 可知,本文考虑了 6 种变压器绕组常见故障,由于每种情况都读取了 3 个测点的磁感应强度,故仿真共取得 297 组数据,其中匝间短路故障共 72 组数据,绕组变形共 225 组数据。对这些数据进行处理,获取每种情况下的 3 个特征值即相关系数、不对称度及分布差异度作为特征向量,最终得到 99 组样本数据。将这些样本分为训练集和测试集后分别进行归一化处理,为保证训练效果,训练样本按 80% 的比例从总样本数据中随机选取,其中训练数据 78 组,测试数据 21 组。

2) 故障分类。

将提取的 78 组训练样本作为一个数据集 $(x_i, t_i)(i=1, 2, \dots, 78)$, 代入 GA-ELM 分类器进行训练,其中,GA-ELM 网络的输入层节点数为 78,输出层节点数与样本标签的维数相同。将隐藏层节点数 i 设置为 20,隐藏层激励函数为“Sigmoid”,利用输出权重矩阵 β 在测试数据集上进行测试。BPNN 的隐藏层节点数是影响分类性能的重要因素,为了比较 GA-ELM 与 BPNN 的效果,将隐藏层节点数同样设置为 20,然后将训练误差设置为 1×10^{-6} ,以“newff”为网络创建函数、“train”为训练函

数、“sim”为测试函数。SVM 的核函数为径向基,其中惩罚因子为 10,核参数为 0.5。GA-ELM 方法分类结果如图 11 所示;各种方法的运行和对比结果如表 5 所示。

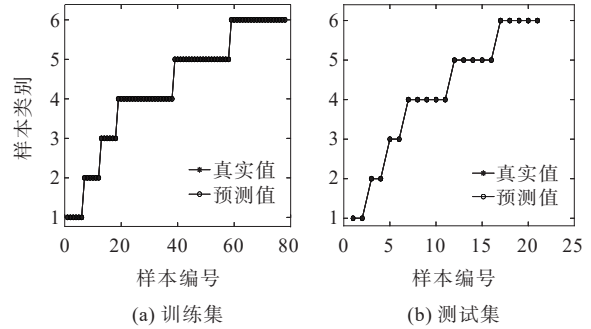


图 11 GA-ELM 运行结果

Figure 11 Running result of GA-ELM

表 5 几种分类方法的性能对比

Table 5 Performance comparison of several classification methods

分类方法	正确率/%		测试时间/s
	训练集	测试集	
BPNN	99.820 0	95.238 1	5.576
SVM	90.476 2	89.743 6	4.729
GA-ELM	100.000 0	100.000 0	2.164

由表 5 可知,对于变压器早期故障的 6 种情况, BPNN、SVM 方法的训练集、测试集正确率在 90% 左右,而本文方法正确率为 100%;BPNN、SVM 方法所用时间较长,不适用于快速分类,本文方法所用时间较短,同时,训练集和测试集正确率均为 100%。证明本文所选的 3 个特征量能够完全有效地反应变压器早期故障的状态。

3) 故障程度判定。

故障分类后需判断故障程度,因此引入欧氏距离,变压器绕组故障的欧氏距离与故障程度的关系曲线如图 12 所示,可知不同种类的故障欧氏距离的变化程度不同。对同程度的故障,匝间短路时磁感应强度分布对称大于不对称分布故障的欧氏距离变化程度;相反,绕组变形时磁感应强度分布不对称大于对称分布故障的欧氏距离变化程度。通过所得到的关系曲线,计算所测得信号的欧氏距离,便可判断故障的严重程度。

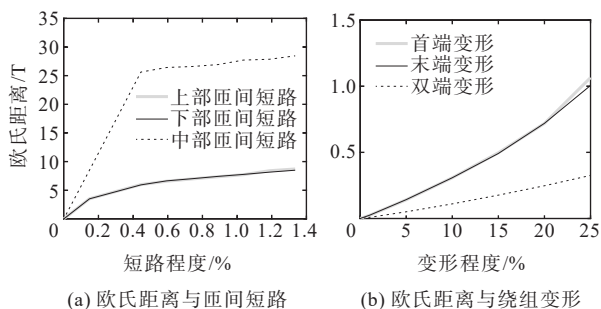


图12 欧氏距离与故障程度关系曲线

Figure 12 Relationship curves between Euclidean distance and fault degrees


4.3 动模实验验证

1) 动模实验模型的建立。

动模实验时使用三相三柱式芯式变压器,采用Ynd11接线,在高压侧绕组处安装光纤传感器,对绕组发生早期故障前、后磁场的变化进行测量,如图13所示。动模实验相关参数: $E=1\text{ kV}$,忽略系统内阻;线路参数:线路长度 $l=200\text{ km}$, $r_l=2.54\ \Omega$, $x_l=34.94\ \Omega$, $c_l=6.72\ \mu\text{F}$;变压器额定容量为 $50\text{ kV}\cdot\text{A}$,额定电压比 $U_1/U_2=1\ 000\text{ V}/400\text{ V}$,频率为 50 Hz ,负荷参数 $Z_l=159.987+j1.358\ \Omega$ 。


2) 实测信号分析。

变压器绕组发生 1.38% 匝间短路时的实测漏磁场信号如图14(a)所示,可以看出信号中含有大量噪声分量;使用本文方法对此信号进行降噪处理,从图14(b)可以看出本文方法去噪效果良好,有效地还原原漏磁场信号。



(a) 变压器主体


(b) 测量系统




(c) 动模实验接线

图13 动模实验实物与接线

Figure 13 Real object and wiring diagram of dynamic model test



(a) 实测漏磁场信号



(b) 降噪后漏磁场信号

图14 实测信号的降噪处理

Figure 14 Noise reduction process of measured signal

将信号去噪后,使用GA-ELM对实测得到的123组数据进行故障分类,其中,匝间短路数据为48组,绕组变形数据为75组,所得结果如图15所示,可知本文方法能准确识别故障类型。

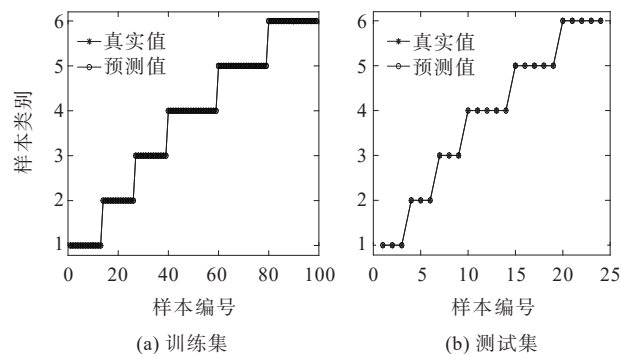


图15 训练集、测试集预测结果

Figure 15 Prediction results of training data and test data

5 结语

本文利用ANSYS仿真软件建立了变压器模型,分析了绕组漏磁场的分布情况,并通过研究漏磁场分布的变化来反应变压器绕组的状态。在对所采集到的漏磁场信号进行处理时,针对传统VMD需要预先设置好参数的问题,采用GA并以样

本熵作为适应度函数来优化VMD参数。由于VMD分解后相关模态仍然存在少量噪声,因此,使用小波阈值法去除残余噪声。通过与EMD、EEMD以及传统小波阈值法的对比,表明本文方法对于含噪漏磁场信号的去噪效果良好。

将漏磁场信号去噪后提取相关系数、不对称度及分布差异度3个特征量,通过GA-ELM分类模型将故障进行分类。结果表明:GA-ELM用于变压器早期故障分类具有有效性,与SVM、BP神经网络相比,GA-ELM具有学习速度快、运算时间短以及结果准确等优点;同时建模和操作所需的数据较少,因此不需要大量的数据进行训练,然后形成欧氏距离与故障程度关系曲线,可实现对变压器绕组早期故障严重程度的判断。通过实验验证了本文所提出的基于改进VMD的去噪和优化ELM变压器故障诊断的有效性。

参考文献:

- [1] 卢仰泽,鲁非,苏翔,等.油浸式变压器内外辐射传热的数值分析[J].高压电器,2022,58(11):47-52+74.
LU Yangze,LU Fei,SU Xiang,et al.Numerical analysis of internal and external radiation heat transfer in oil-immersed transformer[J].High Voltage Apparatus,2022,58(11):47-52+74.
- [2] BEHIJAT V, VAHEDI A, SETAYESHMEHR A, et al. Diagnosing shorted turns on the windings of power transformers based upon online FRA using capacitive and inductive couplings[J]. IEEE Transactions on Power Delivery,2011,26(4):2123-2133.
- [3] 甘团杰,郑建涵,张艳,等.基于领域自适应的变压器状态识别[J].智慧电力,2022,50(2):82-88.
GAN Tuanjie, ZHENG Jianhan, ZHANG Yan, et al. Transformer condition identification based on domain adaptation[J].Smart Power,2022,50(2):82-88.
- [4] 任于展,武仕朴,汪友华,等.基于暂态电流差极值的电力变压器剩磁测量方法[J].电工技术学报,2022,37(5):1088-1097.
REN Yuzhan, WU Shipu, WANG Youhua, et al. Residual flux measurement method of power transformer based on extreme value of transient current difference[J]. Transactions of China Electrotechnical Society, 2022, 37(5):1088-1097.
- [5] 郝治国,张保会,李朋,等.漏电感参数辨识技术在线监测变压器绕组变形[J].高电压技术,2006,32(11):67-70.
HAO Zhiguo, ZHANG Baohui, LI Peng, et al. Online monitoring of transformer winding deformation by leakage inductance parameter identification[J]. High Voltage Engineering,2006,32(11):67-70.
- [6] 赵斌,张闯,李隆,等.电力变压器振动检测装置设计及振动信号去噪方法研究[J].电测与仪表,2021,58(8):118-124.
ZHAO Bin,ZHANG Chuang,LI Long,et al.Research on the design of power transformer vibration detection device and the vibration signal de-noising method[J]. Electrical Measurement & Instrumentation,2021,58(8):118-124.
- [7] 熊尉辰,宋国兵,李洋,等.利用智能电表量测数据的三相四线制配电线路参数辨识[J].电力系统自动化,2022,46(20):155-166.
XIONG Weichen,SONG Guobing,LI Yang,et al.Parameter identification of three-phase four-wire distribution line using smart meter measurement data[J]. Automation of Electric Power Systems,2022,46(20):155-166.
- [8] 张育杰,冯健,李典阳,等.基于油色谱数据的变压器故障征兆新优选策略[J].电网技术,2021,45(8):3324-3331.
ZHANG Yujie, FENG Jian, LI Dianyang, et al. New feature selection method for transformer fault diagnosis based on DGA data[J].Power System Technology, 2021, 45(8):3324-3331.
- [9] 周院超,王雪.基于磁场测量的变压器绕组形变在线监测方法[J].电测与仪表,2017,54(17):58-63+87.
ZHOU Yuanchao, WANG Xue. The on-line monitoring method of transformer winding deformation based on magnetic field measurement[J].Electrical Measurement & Instrumentation,2017,54(17):58-63+87.
- [10] 邓祥力,吴文强,杨梅,等.基于漏磁场和深度信念网络的变压器绕组变形诊断研究[J].变压器,2021,58(8):42-48.
DENG Xiangli,WU Wenqiang,YANG Mei,et al.Research on transformer winding deformation diagnosis based on leakage magnetic field and deep belief network[J]. Transformer,2021,58(8):42-48.
- [11] 潘超,石文鑫,孟涛.单相变压器匝间短路电磁特性研究[J].高电压技术,2020,46(5):1839-1856.
PAN Chao, SHI Wenxin, MENG Tao. Study on

- electromagnetic characteristics of interturn short circuit of single-phase transformer[J]. High Voltage Engineering, 2020,46(5):1839-1852.
- [12] 李晨,李强,孙昭昌,等.变压器绕组变形的影响因素及出口短路后分析[J].变压器,2013,50(8):66-70.
LI Chen, LI Qiang, SUN Zhaochang, et al. Influence factors of transformer winding deformation and analysis after output short circuit[J]. Transformer, 2013, 50(8): 66-70.
- [13] 高宁,高文胜,李福祺,等.变压器局放在线监测中的现场干扰分析[J].变压器,2002,39(1):24-26.
GAO Ning, GAO Wensheng, LI Fuqi, et al. Analysis of on-site noise in partial discharge monitoring of power transformer[J]. Transformer, 2002, 39(1): 24-26.
- [14] 周建,向北平,倪磊,等.基于Shannon熵的自适应小波包阈值函数去噪算法研究[J].振动与冲击,2018,37(16):206-211.
ZHOU Jian, XIANG Beiping, NI Lei, et al. Research on adaptive wavelet packet threshold function denoising algorithm based on Shannon entropy[J]. Journal of Vibration and Shock, 2018, 37(16): 206-211.
- [15] 刘震宇,刘振英,范贺明.基于EMD-ICA的高压电缆局部放电信号去噪研究[J].电力系统保护与控制,2018,46(24):83-87.
LIU Zhenyu, LIU Zhenying, FAN Heming. Research on partial discharge signal denoising of high voltage cable based on EMD-ICA[J]. Power System Protection and Control, 2018, 46(24): 83-87.
- [16] 蒋沅,上官彪,曾竞凯.基于EEMD的改进小波阈值算法在超声水表中的应用[J].振动与冲击,2022,41(5):208-213.
JIANG Yuan, SHANGGUAN Biao, ZENG Jingkai. Application of improved wavelet threshold algorithm based on EEMD in ultrasonic water meter[J]. Journal of Vibration and Shock, 2022, 41(5): 208-213.
- [17] 崔江,唐军祥,张卓然,等.基于极限学习机的航空发电机旋转整流器快速故障分类方法研究[J].中国电机工程学报,2018,38(8):2458-2466.
CUI Jiang, TANG Junxiang, ZHANG Zhuoran, et al. Fast fault classification method research of aircraft generator rotating rectifier based on extreme learning machine[J]. Proceedings of the CSEE, 2018, 38(8): 2458-2466.
- [18] 赵文清,严海,周震东,等.基于残差BP神经网络的变压器故障诊断[J].电力自动化设备,2020,40(2):143-148.
ZHAO Wenqing, YAN Hai, ZHOU Zhendong, et al. Fault diagnosis of transformer based on residual BP neural network[J]. Electric Power Automation Equipment, 2020, 40(2): 143-148.
- [19] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.
- [20] KAZEMI A, MOHAMED A, SHAREEF H, et al. Optimal power quality monitor placement using genetic algorithm and Mallow's C_p [J]. International Journal of Electrical Power & Energy Systems, 2013, 53(1): 564-575.
- [21] 刘云鹏,律方成,李成榕,等.基于数学形态滤波器抑制局部放电窄带周期性干扰的研究[J].中国电机工程学报,2004,24(3):169-173.
LIU Yunpeng, LÜ Fangcheng, LI Chengrong, et al. Study of the mathematical morphological filter in suppressing periodic narrow bandwidth noise of PD[J]. Proceedings of the CSEE, 2004, 24(3): 169-173.