

基于 ST-SVD 与 WOA-SVM 模型的变压器绕组松动故障诊断方法^{*}

薛健桐， 马宏忠

(河海大学 能源与电气学院, 江苏 南京 211100)

摘要：为了深入研究变压器振动信号包含的大量故障信息, 提出了一种基于 S 变换奇异值分解(ST-SVD)与鲸鱼优化支持向量机(WOA-SVM)模型的变压器绕组松动故障诊断方法。首先, 基于变压器故障模拟试验平台采集变压器绕组处于不同状态下的振动信号。其次, 对变压器振动信号进行 S 变换获取其时频矩阵。再次, 计算出时频矩阵对应的幅值矩阵进行 SVD, 并定义特征向量。最后, 采用鲸鱼优化算法优化 SVM 模型参数, 并输入特征向量完成故障诊断。试验结果表明, 所提方法故障识别准确率高于传统方法模型, 适用于变压器绕组松动故障诊断。

关键词：变压器绕组松动; 振动信号; S 变换; 奇异值分解; 鲸鱼优化支持向量机; 故障诊断

中图分类号：TM41 **文献标志码：**A **文章编号：**1673-6540(2023)09-0057-06

doi: 10.12177/emca.2023.022

Fault Diagnosis Method of Transformer Winding Looseness Based on ST-SVD and WOA-SVM Model^{*}

XUE Jiantong, MA Hongzhong

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

Abstract: In order to further study the large amount of fault information contained in transformer vibration signals, a fault diagnosis method for transformer winding looseness based on S-transform singular value decomposition (ST-SVD) and support vector machine optimized by whale optimization algorithm (WOA-SVM) model was proposed. Firstly, based on the transformer fault simulation experiment platform, the vibration signals of transformer windings in different states were collected. Secondly, the time-frequency matrix of the transformer vibration signal was obtained by S-transformation. Thirdly, calculating the amplitude matrix corresponding to the time-frequency matrix for SVD, and defining the feature vector. Finally, the parameters of SVM model were optimized by whale optimization algorithm, and the fault diagnosis was completed by inputting feature vectors. The experimental results show that the accuracy of fault identification of the proposed method is higher than that of the traditional method model, and it is suitable for the diagnosis of transformer winding looseness fault.

Key words: transformer winding looseness; vibration signal; Stransformation; singular value decomposition; support vector machine optimized by whale optimization algorithm; fault diagnosis

收稿日期: 2022-11-21; 收到修改稿日期: 2023-01-30

* 基金项目: 国家自然科学基金项目(51577050); 国网江苏省电力有限公司科技项目(J2021053)

作者简介: 薛健桐(1999—), 男, 硕士研究生, 研究方向为变压器状态监测与故障诊断。

马宏忠(1962—), 男, 教授, 博导, 研究方向为电力设备状态监测与故障诊断。(通信作者)

0 引言

变压器作为电力远距离输送的核心设备,其正常运行是维持电网安全、可靠的关键,因此也是变电站运维的重点对象^[1-2]。然而,变压器绕组由于固有的运输安装过程中产生的轻微移位以及长期经受短路冲击电流造成的松动变形情况,使得该原因导致的事故发生率成为首位^[3-4]。因此,研究变压器绕组松动故障诊断技术,及时发现、排查出变压器绕组故障隐患,对变压器稳定运行具有重要的现实意义^[5-6]。

由于变压器绕组松动与变压器异常振动存在因果关系,因此目前振动法被广泛应用于变压器的故障诊断^[7],基于变压器振动信号的时频分析一直是热点。文献[8]采用快速傅里叶变换(FFT)方法对变压器振动信号进行处理,揭示了振动信号50 Hz分量及其部分倍频分量等新特征频率来反映变压器内部绕组松动变形故障,并基于此建立了诊断模型,实现了绕组松动故障诊断与初步定位。文献[9]采用希尔伯特-黄变换(HHT)方法,对变压器振动信号经验模态分解(EMD)后的各层本征模态函数(IMF)进行希尔伯特变换,以三维希尔伯特能量谱及边界谱反映变压器隐含的铁心振动特征。文献[10]基于小波变换方法,对变压器开关闭换产生的绕组振荡波进行时频特性分析,通过量化时频信号特征反映变压器绕组的机械状态。上述信号分析方法都在处理变压器振动信号方面取得了良好效果,但此类方法仍有其局限性,例如小波变换的母小波和分解层数的确定会直接影响信号分析效果,HHT对噪声敏感容易导致结果误差较大等。S变换(ST)是近年兴起的一种时频分析方法,其窗函数宽度随信号频率变化而变化,对信号的分辨率高且抗噪能力强,十分适合处理非平稳信号^[11]。同时,奇异值分解(SVD)是一种成熟的矩阵特征提取技术,其已和多种时频分析方法结合,应用于图像处理、模式识别等许多领域^[12]。

支持向量机(SVM)是一种常用的机器学习方法,在处理小样本集分类时展现出独特的优越性^[13]。文献[14]将鲸鱼优化算法(WOA)引入SVM模型中对惩罚因子c与核函数参数g进行寻优,利用随机森林(RF)特征优选构建变压器油中

溶解气体特征向量,实现变压器故障诊断模型的构建,验证了WOA-SVM模型的优越性,实现了较好的应用效果。

综上所述,本文提出一种基于ST-SVD与WOA-SVM模型的变压器绕组松动故障诊断方法。首先采用S变换得到变压器振动信号的时频矩阵,经转化为幅值矩阵后进行SVD得到相应的矩阵奇异值,然后定义特征奇异值并提取出来组成特征向量,最后采用WOA优化SVM的c、g参数,输入训练样本构建WOA-SVM模型并对测试样本进行分类诊断,通过与K-means聚类、SVM和粒子群优化(PSO)-SVM模型的诊断准确率进行对比,验证了本文所提方法的有效性与可行性。

1 S 变换和 SVD

1.1 S 变换原理

S变换是Stockwell等^[15]于1996年提出的信号处理方法,其综合了小波变换和短时傅里叶变换的特点,其窗函数与频率相关,对噪声不敏感,信号分辨率高,十分适合处理非平稳信号。

对于连续时间信号x(t),S变换如下:

$$S_x(\tau, f) = \int_{-\infty}^{+\infty} x(t) w(\tau - t, f) e^{-2\pi ft} dt \quad (1)$$

$$w(\tau - t, f) = -\frac{f}{\sqrt{2\pi}} e^{-\frac{(\tau-t)^2}{2\sigma^2}} \quad (2)$$

式中:w(τ-t, f)为高斯窗函数;t为平移因子;σ=1/f。

由此可以看出,S变换的高斯窗函数的宽度和高度随着频率f的变化而变化,因此在低频段具有高频率分辨率,在高频段具有高时间分辨率^[16]。

实际应用中,S变换需离散化处理,可表示为

$$\begin{cases} S\left[jT, \frac{n}{NT}\right] = \sum_{m=0}^{N-1} X\left[\frac{m+n}{NT}\right] e^{-\frac{2\pi^2 m^2}{n^2}} e^{-\frac{j2\pi m j}{N}} \\ S[jT, 0] = \frac{1}{N} \sum_{m=0}^{N-1} x\left(\frac{m}{NT}\right) \end{cases} \quad (3)$$

式中: $X\left[\frac{n}{NT}\right] = \frac{1}{N} \sum_{k=0}^{N-1} x[kT] e^{-\frac{j2\pi n k}{N}}$ 为x[kT]的离散傅里叶变换,m、n,j=1,2,⋯,N-1;T为采样周期。

1.2 SVD 特征提取

矩阵经过SVD得到的奇异值能够充分表示

矩阵包含的信息^[17],因而广泛应用于信号的特征提取。任意一个矩阵 $M_{m \times n}$,存在着正交矩阵 $U_{m \times m}$ 和 $V_{n \times n}$,将其分解为

$$M = USV^T \quad (4)$$

$$S = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_r, \dots, 0) \quad (5)$$

式中: $\sigma_1, \sigma_2, \dots, \sigma_r$ 为矩阵 M 的奇异值。

变压器振动信号经 S 变换后得到的是时频矩阵,需将各元素求模后得到幅值矩阵再进行 SVD。因此,得到奇异值 $\sigma_1, \sigma_2, \dots, \sigma_r$ 反映的是所采集变压器振动信号的特征量,并且由相应幅值矩阵唯一确定^[18]。由于奇异值个数受到幅值矩阵行列数大小的影响,一般数量很多,因此需进一步处理从而突出变压器振动信号在绕组正常与松动状态下的相对变化^[19]。本文选择计算所有奇异值的最大值 k_1 、平均值 k_2 和标准差 k_3 作为特征值。表达式如下:

$$k_1 = \max(\sigma_1, \sigma_2, \dots, \sigma_r) \quad (6)$$

$$k_2 = \frac{\sigma_1 + \sigma_2 + \dots + \sigma_r}{r} \quad (7)$$

$$k_3 = \sqrt{\frac{1}{r-1} \sum_{i=1}^r (\sigma_i - k_1)^2} \quad (8)$$

将三个特征值组成特征向量 $[k_1, k_2, k_3]$,通过各元素的变化,反映变压器绕组正常与松动状态下的特征信息,作为本文故障诊断的依据。

2 WOA-SVM 模型

2.1 WOA

WOA 是 Mirjalili 等^[20]于 2016 年提出的新型群智能优化算法。该算法模拟了鲸鱼捕猎时选择包围猎物和发出气泡网的两种行为,用来进行参数寻优。算法前期体现出全局搜索,后期体现出局部搜索,其具有参数量少、过程简便的特点。假设解空间维数为 D ,则鲸鱼个体的位置为

$$X = (x_1, x_2, \dots, x_D) \quad (9)$$

每只鲸鱼选择包围猎物和发出气泡网的概率相等,都为 0.5。

若选择包围猎物,则还分为向最优个体位置移动和向随机个体位置移动两种情况。

向最优个体位置移动时,位置更新公式为

$$X(t+1) = X_{\text{best}}(t) - A \cdot D \quad (10)$$

$$D = |C \cdot X_{\text{best}}(t) - X(t)| \quad (11)$$

$$A = 2a \cdot r - a \quad (12)$$

$$C = 2 \cdot r \quad (13)$$

式中: $X_{\text{best}}(t)$ 表示当前最优个体位置; a 随迭代过程从 2 线性减少到 0; r 为 $[0, 1]$ 的随机向量。

向随机个体位置移动时,位置更新公式为

$$X(t+1) = X_{\text{rand}}(t) - A \cdot D \quad (14)$$

$$D = |C \cdot X_{\text{rand}}(t) - X(t)| \quad (15)$$

式中: $X_{\text{rand}}(t)$ 为当前随机个体位置。

两种移动方式的选择条件为: $|A| < 1$ 时,向最优个体位置移动; $|A| \geq 1$ 时,向随机个体位置移动。

若选择发出气泡网,位置更新公式为

$$X(t+1) = D' \cdot e^{bl} \cdot \cos(2\pi l) + X(t) \quad (16)$$

$$D' = |X_{\text{best}}(t) - X(t)| \quad (17)$$

式中: b 为定义螺旋形状的常数; l 为 $[-1, 1]$ 的随机数。

2.2 基于 WOA 的 SVM 参数寻优

SVM 因在小样本分类中展现出的优良性能而被广泛应用于工程实际中^[21]。实际应用中使用的 SWM 一般为线性不可分 SVM,通过引入核函数,将低维样本空间映射到高维,实现样本类型的划分。线性不可分 SVM 的概念详见文献[22]。本文采用 WOA 对影响 SVM 性能的重要参数——惩罚因子 c 和核函数参数 g 进行优化,具体步骤如下。

(1) 初始化 WOA 各参数,如鲸鱼个数 N 、最大迭代次数等;设置惩罚因子 c 和核参数 g 作为鲸鱼位置向量的元素并赋初值;

(2) 将预测错误率作为适应度函数,因此每次迭代后最低的适应度值即为最优个体;

(3) 每个个体选择包围猎物或者发出气泡网的位置移动方式;

(4) 若选择包围猎物,则根据 $|A|$ 大小按照式(10)或式(14)更新位置并计算各适应值选出最优个体。若选择发出气泡网,则按照式(16)更新位置并计算各适应值选出最优个体;

(5) 重复进行步骤(3)~(4),直到达到最大迭代次数。

3 基于 ST-SVD 与 WOA-SVM 的故障诊断模型

本文所提基于 ST-SVD 与 WOA-SVM 模型的

变压器绕组松动故障诊断方法的诊断流程如图 1 所示, 具体步骤如下。

步骤 1: 在变压器表面不同位置放置振动传感器采集振动信号;

步骤 2: 将振动信号进行 S 变换得到的时频矩阵转换成幅值矩阵, 再对其进行 SVD 得到多个奇异值;

步骤 3: 按照式(6)~(8)计算出特征向量, 并分为训练样本和测试样本;

步骤 4: 采用 WOA 优化 SVM 的参数 c, g , 以最佳参数输入训练样本构建 WOA-SVM 故障诊断模型;

步骤 5: 将测试样本输入训练好的模型中, 输出结果即为故障诊断结果。



图 1 基于 ST-SVD 与 WOA-SVM 模型的变压器绕组松动故障诊断流程图

4 试验结果与分析

为验证本文所提基于 ST-SVD 与 WOA-SVM 模型的变压器绕组松动故障诊断方法的有效性, 在实验室环境下搭建了变压器模拟故障试验平台开展试验, 如图 2 所示。

由图 2 可知, 10 kV 变压器低压侧由调压器将 220 V 电压升高至 380 V 输入, 经限流电阻抑制合闸瞬间产生冲击电流; 高压侧接入容量均为 30 Mvar 的电容器与电抗器以模拟变压器负载情况。由于变压器绕组与油箱顶部相连, 振动信号在变压器顶部的采集效果更好, 因此试验时在变压器顶部布置三个测点, 测点布置图如图 3 所示。振动传感器为 IEPE 型压电式传感器, 型号为

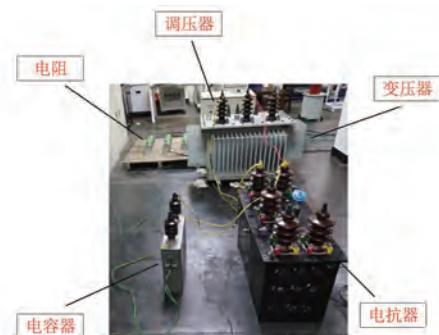


图 2 变压器模拟故障试验平台

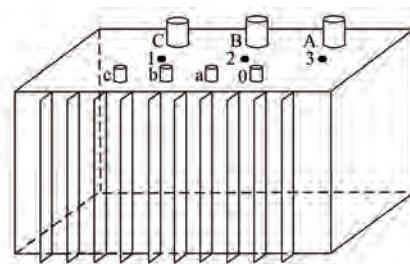


图 3 变压器测点布置图

1A212E; 采集仪型号为 DH5922, 采样频率设为 20 kHz。

故障模拟采用调节变压器内部绕组预紧螺母松紧程度的方式。分别模拟了变压器绕组正常、预紧力下降 40% 和预紧力下降 80% 的状态, 故障模拟图如图 4 所示。



图 4 故障模拟图

试验过程中对变压器绕组处于 3 种状态下的振动信号进行多次采集。以测点 1 为例, 当变压器绕组处于预紧力下降 40% 状态下的振动信号时域图如图 5 所示。对其进行 S 变换后对所得时频矩阵求取幅值矩阵, 所得时频谱图如图 6 所示。

在得到变压器 3 种状态振动信号的幅值矩阵作为特征矩阵后, 对其进行 SVD, 所得奇异值按照

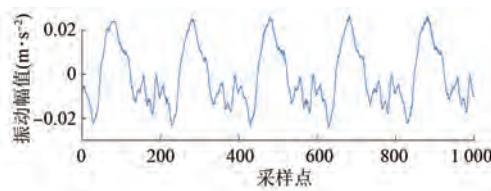


图 5 变压器绕组处于预紧力下降 40% 状态下的测点 1 振动信号时域图

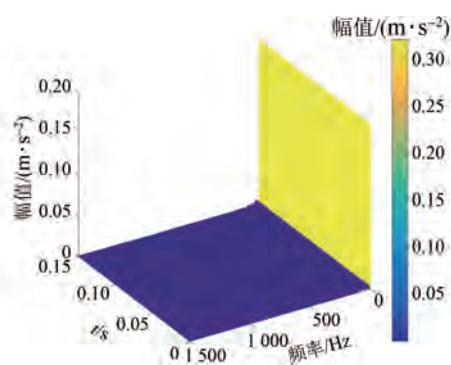


图 6 S 变换时频谱图

式(6)~式(8)计算出相应的 k_1 、 k_2 、 k_3 。表 1 为其中的一组计算结果。

表 1 特征奇异值计算结果

绕组状态	k_1	k_2	k_3
正常	10.991 6	0.008 3	0.283 9
预紧力下降 40%	17.973 3	0.014 2	0.464 6
预紧力下降 80%	15.820 9	0.013 3	0.360 3

由表 1 可知,本文所提变压器绕组处于 3 种状态下的振动信号所提取的特征奇异值具有较好的区分性,表明基于 ST-SVD 的故障特征提取方法的有效性,也表明可通过聚类算法对 3 种状态下的特征向量进行分类。

本文对每种状态的变压器振动信号分别提取 150 组特征向量作为训练样本,在采用 WOA 对 SVM 参数寻优时,设置 c 、 g 的取值范围均为 $[0, 500]$,最大迭代次数为 50。同时,为了对比验证本文所提方法的有效性,又构建了 K-means 聚类、传统 SVM 和 PSO-SVM 模型。对每种状态的变压器振动信号额外提取 40 组特征向量作为测试样本输入上述模型中。各模型的诊断结果如表 2~表 5 所示。图 7 为各模型诊断结果的对比图。

表 2 WOA-SVM 模型诊断结果

绕组状态	正确样本/组	准确率/%
正常	39	97.5
预紧力下降 40%	37	92.5
预紧力下降 80%	38	95.0
合计	114	95.0

表 3 K-means 聚类诊断结果

绕组状态	正确样本/组	准确率/%
正常	34	85.0
预紧力下降 40%	33	82.5
预紧力下降 80%	31	77.5
合计	98	81.7

表 4 传统 SVM 模型诊断结果

绕组状态	正确样本/组	准确率/%
正常	34	85.0
预紧力下降 40%	35	87.5
预紧力下降 80%	33	82.5
合计	102	85.0

表 5 PSO-SVM 模型诊断结果

绕组状态	正确样本/组	准确率/%
正常	35	87.5
预紧力下降 40%	36	90.0
预紧力下降 80%	35	87.5
合计	106	88.3

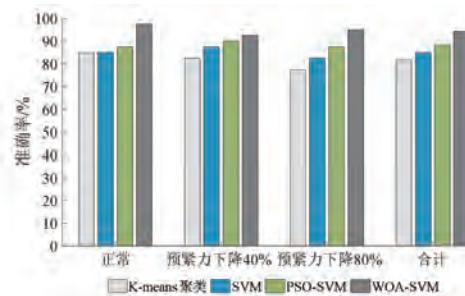


图 7 各模型诊断结果对比图

由图 7 可知,本文所提基于 ST-SVD 与 WOA-SVM 模型的变压器绕组松动故障诊断准确率为 95.0%,而在输入特征向量相同时,K-means 聚类、SVM 和 PSO-SVM 故障诊断模型的准确率分别为

81.7%、85.0% 和 88.3%。这表明了本文所提故障诊断方法的准确率高于传统方法模型,适用于变压器绕组松动故障诊断。

5 结语

本文提出了一种基于 ST-SVD 与 WOA-SVM 模型的变压器绕组松动故障诊断方法。通过 S 变换获得变压器振动信号的时频矩阵,转化为幅值矩阵后,经 SVD 得到多个奇异值计算出特征向量,采用 WOA 优化 SVM 的 c, g 参数,用上述特征提取方法提取出的训练样本和测试样本分别构建 WOA-SVM 模型并验证该模型的有效性,结果表明其诊断精度高于 K-means 聚类、SVM 和 PSO-SVM 模型的诊断精度。

【参考文献】

- [1] 齐波, 张鹏, 张书琦, 等. 数字孪生技术在输变电设备状态评估中的应用现状与发展展望[J]. 高电压技术, 2021, 47(5): 1522.
- [2] 李朋, 张保会, 郝治国, 等. 基于电气量特征的变压器绕组变形监测技术现状与展望[J]. 电力自动化设备, 2006(2): 28.
- [3] 弓杰伟, 马宏忠, 姜宁, 等. 电力变压器的有限元建模与绕组松动分析[J]. 电力自动化设备, 2016, 36(4): 78.
- [4] 刘宝稳, 马宏忠, 李凯, 等. 大型变压器绕组轴向固有频率振动分布特性与试验分析[J]. 高电压技术, 2016, 42(7): 2329.
- [5] 杨擎柱, 程养春, 李斐然, 等. 基于现场数据的变压器首次故障率研究[J]. 高电压技术, 2022, 48(5): 1855.
- [6] 戎子睿, 林湘宁, 金能, 等. 基于相空间轨迹识别和多判据融合的变压器保护新策略[J]. 中国电机工程学报, 2020, 40(6): 1924.
- [7] 吴振宇, 周利军, 周祥宇, 等. 基于振荡波的变压器绕组故障诊断方法研究[J]. 中国电机工程学报, 2020, 40(1): 348.
- [8] 马宏忠, 耿志慧, 陈楷, 等. 基于振动的电力变压器绕组变形故障诊断新方法[J]. 电力系统自动化, 2013, 37(8): 89.
- [9] 熊卫华, 赵光宙. 基于希尔伯特-黄变换的变压器铁心振动特性分析[J]. 电工技术学报, 2006(8): 9.
- [10] 刘红文, 王科, 周祥宇, 等. 基于时频变换的变压器绕组振荡波信号分析方法[J]. 高压电器, 2020, 56(12): 264.
- [11] 龙嘉川, 王先培, 代荡荡, 等. 基于改进 S 变换的超高频局部放电信号特征提取及分类[J]. 高电压技术, 2018, 44(11): 3649.
- [12] 汤占军, 孙润发. 基于多尺度模糊熵和 STOA-SVM 的风机轴承故障诊断[J]. 电机与控制应用, 2021, 48(12): 66.
- [13] 徐萌. 基于 MA-SVM 方法的短期光伏功率预测[J]. 电机与控制应用, 2022, 49(7): 104.
- [14] 安国庆, 史哲文, 马世峰, 等. 基于 RF 特征优选的 WOA-SVM 变压器故障诊断[J]. 高压电器, 2022, 58(2): 171.
- [15] STOCKWELL R G, MANSINHA L, LOWE R P. Localization of the complex spectrum: the S transform [J]. IEEE Transactions on Signal Processing, 1996, 44(4): 998.
- [16] 刘宝稳, 汤容川, 马征洲, 等. 基于 S 变换 D-SVM AlexNet 模型的 GIS 机械故障诊断与试验分析[J]. 高电压技术, 2021, 47(7): 2526.
- [17] 宁暑光, 何怡刚, 程彤彤, 等. 基于自适应 S 变换与截断紧致奇异值分解的局部放电源复杂染噪特征提取方法[J]. 电工技术学报, 2022, 37(15): 3951.
- [18] 郭凤仪, 高洪鑫, 王智勇, 等. 基于 ST-SVD-PCA 的串联故障电弧特征提取方法[J]. 煤炭学报, 2018, 43(3): 888.
- [19] 卢其威, 王涛, 李宗睿, 等. 基于小波变换和奇异值分解的串联电弧故障检测方法[J]. 电工技术学报, 2017, 32(17): 208.
- [20] MIRJALILI S, LEWIS A. The whale optimization algorithm[J]. Advances in Engineering Software, 2016, 95: 51.
- [21] 李学明, 刘侃, 徐绍龙, 等. 基于 LS-SVM 的列车牵引电机电流实时估计[J]. 电机与控制应用, 2021, 48(9): 67.
- [22] 周志华. 机器学习[M]. 北京: 清华大学出版社, 2016: 126.