

基于 SSWT-GLCM 与改进 WOA-SVM 的 变压器机械故障时频诊断*

杨 义, 李晓华, 李俊聪, 赵文彬, 陈皖皖, 夏能弘

(上海电力大学电气工程学院 上海, 200090)

摘要 为进一步提高变压器故障诊断精度,提出一种基于同步压缩小波变换(synchrosqueezed wavelet transform,简称 SSWT)-灰度共生矩阵(gray-level co-occurrence matrix,简称 GLCM)的变压器机械故障时频诊断方法。首先,利用 SSWT 对变压器振动信号进行时频分析,得到能量堆叠密集的二维时频图,有效保留了变压器振动信号的主要特征信息;其次,联合描述区域像素关系的 GLCM 提取出二维时频图的主要特征信息,为后续故障诊断模型提供有效的特征参数;最后,通过改进鲸鱼算法优化(whale optimization algorithm,简称 WOA)对支持向量机(support vector machine,简称 SVM)的关键参数进行优化,建立了基于改进 WOA-SVM 的变压器典型机械故障时频诊断模型。实验结果表明,所构建的改进 WOA-SVM 故障诊断模型具有较高的识别精度和运算效率,为基于振动信号的变压器机械故障时频诊断提供了技术支撑。

关键词 变压器;同步压缩小波变换;灰度共生矩阵;改进鲸鱼算法优化-支持向量机算法;故障分类

中图分类号 TM933

引 言

电力变压器的振动信号中包含着丰富的故障信息,对其进行时频分析可全面揭示振动信号不同频率分量的时变特性,是实现变压器故障诊断的有效手段^[1-3]。传统的时频分析方法包括短时傅里叶变换(short-time Fourier transform,简称 STFT)^[4-5]、连续小波变换(continuous wavelet transform,简称 CWT)^[6]以及 S 变换(S-transformation,简称 ST)^[7]等,但上述方法所得时频谱中的各频带能量离散分布于中心频带附近的较宽范围内,导致频谱存在能量泄露、信息遗失、宽频模糊和频带混叠等问题,极大降低了变压器故障诊断精度。

相比于时频分析方法,同步压缩小波变换^[8]利用同步压缩算法将小波变换后各频带能量压缩到一定阈值范围内,从而实现高能量堆叠密度。同时,SSWT 可将变压器振动信号直接进行逆变换,以实现信号的无损显示,消除频带交叉混叠等问题。然而,仅通过 SSWT 获得的二维时频分析结果无法实现变压器机械故障诊断、分类和预测。随着人工智能、数字孪生等技术的快速发展,各种机器学习方法如人工神经网络^[9]、专家系统^[10]和支持向量机^[11-12]等

被应用到变压器故障诊断中^[13-14]。但是,机器学习需要大量数据训练才能达到理想的效果,而变压器的故障数据样本较少,难以满足所需的大量数据。

SVM 在理论上适用于小样本训练,且 SVM 算法简单,具有良好的鲁棒性和出色的泛化能力^[15],弥补了变压器故障数据量较少的缺点,但其对初始参数要求较高。利用算法对 SVM 的参数进行寻优,可以显著改善 SVM 的识别精度和运算效率。传统 WOA、粒子群优化算法(particle swarm optimization,简称 PSO)和灰狼优化算法(grey wolf optimizer,简称 GWO)等被应用到变压器故障诊断中,以改善 SVM 的识别效果^[16],但这些方法依旧存在求解精度较低和易陷入局部最优等缺点。

针对上述问题,笔者提出一种基于 SSWT-GLCM 纹理特征与改进 WOA-SVM 的变压器机械故障时频诊断方法。首先,利用 SSWT 算法对处理后的数据进行同步压缩变化,将一维时频信号映射到二维时频图,得到能量堆叠密集的二维时频图;其次,利用 GLCM 挖掘图像的二维纹理特征;最后,利用改进 WOA,增加准反向学习机制、非线性收敛因子和自适应收敛策略,优化 SVM 中的惩

* 国家自然科学基金资助项目(51607110)

收稿日期:2022-02-22;修回日期:2022-06-08

罚参数 C 和核函数参数 g , 提高算法的收敛速度和精度, 并通过与原始 WOA, PSO 和 GWO 进行寻优测试对比, 验证了所提算法的优越性。

1 基于 SSWT-GLCM 的变压器振动信号纹理特征提取

变压器内部振动信号通过机械和油两个路径传递到机壳表面, 因此通过对机壳表面的振动信号进行分析, 可以发现其中隐藏的变压器故障信息。利用 SSWT-GLCM 提取机壳表面振动信号的信息特征, 以实现变压器振动信号纹理特征提取。

1.1 同步压缩小波变换

SSWT 是利用时频点附近的相位信息对时频分布进行频率重排^[17], 其相较于小波包变换 (wavelet packet transformer, 简称 WPT) 和其他时频提取方法具有时频能量堆积密集、时频线更精细等优点。笔者采用 SSWT 算法对变压器箱体振动信号进行分析。假设一般信号 $s(t)$ 为

$$s(t) = A \cos(\omega t) \phi(t) \quad (1)$$

连续小波变换为

$$W_s(a, \tau) = \int_{-\infty}^{\infty} s(t) a^{-1/2} \overline{\psi\left(\frac{t-\tau}{a}\right)} dt \quad (2)$$

其中: $\psi(\xi)$ 为小波母函数的傅里叶变换函数。

根据帕塞瓦尔定理, 可将式(2)改为

$$\begin{aligned} W_s(a, \tau) &= \frac{1}{2\pi} \int S(\xi) a^{1/2} \overline{\psi(a\xi)} e^{j\tau\xi} d\xi = \\ &= \frac{A}{4\pi} \int [\delta(\xi - \omega) + \delta(\xi + \omega)] a^{1/2} \overline{\psi(a\xi)} e^{j\tau\xi} d\xi = \\ &= \frac{A}{4\pi} a^{1/2} \overline{\psi(a\xi)} e^{j\tau\xi} \end{aligned} \quad (3)$$

其中: $S(\xi)$ 为信号 $s(t)$ 的傅里叶变换; $W_s(a, \tau)$ 为小波系数。

当 $\xi = \omega_0$ 时, $W_s(a, \tau)$ 应聚合于 $a = \omega_0/\omega$ 处, 但实际上参数会在 $a = \omega_0/\omega$ 附近的区域离散, 从而导致时频线显示模糊不清而容易混淆。尽管 $W_s(a, \tau)$ 在尺度 a 处会发生离散, 但原信号频率在 τ 方向仍有保留。因此, 可以利用式(3)排除时间尺度平面上满足 $W_s(a, \tau) \neq 0$ 的所有点 (a, τ) 的频率, 从而实现同步压缩过程, 即

$$\omega_s(a, \tau) = -j(W_s(a, \tau))^{-1} \frac{\partial}{\partial \tau} W_s(a, \tau) \quad (4)$$

对式(4)进行离散化计算, 取离散化尺度 $a_k - a_{k-1} = (\Delta a)_k$, 则其同步压缩变换 $T_s(\omega, \tau)$ 可写为

$$T_s(\omega, \tau) = (\Delta\omega)^{-1} \sum_{a_k: |\omega(a_k, \tau) - \omega_\ell| \leq \Delta\omega/2} W_s(a_k, \tau) a_k^{-3/2} (\Delta a)_k \quad (5)$$

其中: ω_ℓ 为 $T_s(\omega, \tau)$ 的中心频率, 其位于区间 $\left[\omega_\ell - \frac{\Delta\omega}{2}, \omega_\ell + \frac{\Delta\omega}{2}\right]$ ($\Delta\omega = \omega_\ell - \omega_{\ell-1}$) 内。

同步压缩小波变换还可以重新构建信号, 即

$$\begin{aligned} \int_0^\infty W_s(a, \tau) a^{-3/2} da &= \\ \frac{1}{2\pi} \int_{-\infty}^\infty \int_0^\infty S(\xi) \overline{\psi(a\xi)} e^{j\tau\xi} a^{-1} da d\xi &= \\ \frac{1}{2\pi} \int_0^\infty \int_0^\infty S(\xi) \overline{\psi(a\xi)} e^{j\tau\xi} a^{-1} da d\xi &= \\ \int_0^\infty \overline{\psi(\xi)} \frac{d\xi}{\xi} \frac{1}{2\pi} \int_0^\infty S(\xi) e^{j\tau\xi} d\xi \end{aligned} \quad (6)$$

考虑 $s(t)$ 为实信号情况时 $S(\xi) = \overline{S(-\xi)}$, 则

$$s(\tau) = \frac{1}{\pi} \operatorname{Re} \left[\int_0^\infty S(\xi) \right] e^{j\tau\xi} d\xi \quad (7)$$

其中: $\operatorname{Re}(\bullet)$ 表示取实部的过程。

设 $C_\psi = \frac{1}{2} \int_0^\infty \overline{\psi(\xi)} \frac{d\xi}{\xi}$, 由式(6)和式(7)可得

$$s(\tau) = \operatorname{Re} \left[C_\psi^{-1} \int_0^\infty W_s(a, \tau) a^{-3/2} da \right] \quad (8)$$

对于离散化尺度为 a 的情况, 式(8)可改写为

$$\begin{aligned} s(\tau) &= \operatorname{Re} \left[C_\psi^{-1} \sum_k W_s(a, \tau) a^{-3/2} (\Delta a)_k \right] = \\ &= \operatorname{Re} \left[C_\psi^{-1} \sum_k T_s(\omega_\ell, \tau) (\Delta\omega) \right] \end{aligned} \quad (9)$$

1.2 时频图像特征提取

基于颜色、形状或纹理提取图像特征, 是图像特征提取的3个常用方法。其中: 颜色仅能简单描述图像特征, 无法反映图像中颜色的具体位置和局部信息; 对于基于形状特征提取的方法, 必须先对图像进行分割预处理, 这会引起形状特征参数准确性的波动。因此, 笔者选取能抗干扰的纹理特征提取方法。纹理是以计算多个像素点之间的特征而得到的统计特征, 能显示各部分之间的联系。

GLCM 是一种纹理统计方法, 可以描述具有某种空间位置关系的两个像素灰度的联合分布。假定某图像尺寸为 $L_x \times L_y$, 即由 $L_x \times L_y$ 个像素点组成的图像灰度级别为 G 。以 $X = (1, 2, \dots, N_x)$ 表示水平空间域, 以 $Y = (1, 2, \dots, N_y)$ 表示垂直空间域, $N = \{1, 2, \dots, G\}$ 为灰度级数域, GLCM 矩阵可表示为图像空间域向灰度级数域的映射, 即 $f: X \times Y \rightarrow N$ 。上述映射和像素点之间的分布关系蕴含着

图像的纹理特征, GLCM就是一种提取像素点分布规律的统计方法。

除了灰度等级 G 外, 方向 θ 和步长 d 的选取也是两个关键因素。若纹理较细且不规则, d 比纹理基元大, GLCM 趋向于均匀分布; 反之, 若纹理粗糙且规则, d 选取较小, 则矩阵倾向于对角分布。不同方向上 d 的选取如表 1 所示。

表 1 不同方向上 d 的选取

Tab.1 Selection of d in different directions

$\theta/(^\circ)$	水平方向 距离	垂直方向 距离	$\theta/(^\circ)$	水平方向 距离	垂直方向 距离
0	d	0	90	0	$-d$
45	d	d	135	d	$-d$

通过 GLCM 可得纹理特征向量: $T=[a_1 \ b_1 \ a_2 \ b_2 \ a_3 \ b_3 \ a_4 \ b_4]$, 其中: $a_1 \sim b_4$ 分别代表能量均值、能量标准差、熵均值、熵标准差、惯性矩均值、惯性矩标准差、相关性均值和相关性标准差^[18]。

2 改进 WOA-SVM 的变压器故障诊断模型

通过 SSWT 获得的二维时频分析结果无法实现变压器机械故障分类、诊断和预测, 因此笔者采用算法简单、具有良好鲁棒性和泛化能力的故障分类器 SVM, 并利用改进 WOA 优化其参数 C 和 g , 可提高其分类速度和精度。

2.1 SVM 分类原理

SVM 分类策略是把分类问题转变为求解一个凸集二次优化问题, 即特征空间上的间隔如何能达到最大^[19]。SVM 数据分类方法有 2 种: ①利用线性函数划分; ②利用核函数实现向高维的替代映射, 将核函数应用到原输入数据上即可, 计算仍在原低维数据空间进行, 避免了高维运算, 该核函数的可选项包括高斯径向基函数核函数和 S 型核函数等。由于高斯核函数应用广泛且灵活, 因此本研究采用高斯核函数进行映射变化。其表达式为

$$k(x_1, x_2) = \exp(-g \|x_1 - x_2\|^2) \quad (g > 0) \quad (10)$$

其中: g 为核函数参数。

为避免某些异常值对分类效果的影响, 引入松弛变量, 即

$$\begin{aligned} \min & \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n \xi_i \\ \text{s.t.} & y_i(\omega^\top x_i + b) \geq 1 - \xi_i \quad (\xi_i \geq 0; i = 1, 2, \dots, n) \end{aligned} \quad (11)$$

其中: C 为惩罚参数; ξ_i 为松弛变量。

由式 (10) 和式 (11) 可知, C 和 g 的选择将决定 SVM 分类器最终结果的优劣。 C 和 g 的选择不同, 故障诊断精度也不同, 因此引入改进鲸鱼寻优算法, 对 SVM 参数进行联合寻优。

2.2 改进 WOA 算法

传统 WOA 算法分为 3 个阶段, 分别为包围捕食、螺旋更新和搜寻猎物。鲸鱼首先获取目标信息, 通过搜寻包围和螺旋逼近的方式接近目标, 实现寻优的目的^[19-21]。传统 WOA 算法存在求解精度低和易陷入局部最优的缺点, 因此笔者从初始化种群、个体方位更新策略以及防止陷入最优等方面对传统 WOA 算法进行改进。

1) 准反向学习初始化种群。基本鲸鱼优化算法初始随机性大, 为了克服这个缺点^[20], 引入反向学习方法对其进行改进。

假设鲸鱼种群规模为 N , 搜索空间为 d 维, 第 i 只鲸鱼在第 d 维空间中的位置可表示为

$$x_i^j \in [a_i^j, b_i^j] \quad (j = 1, 2, \dots, d) \quad (12)$$

其中: a_i^j, b_i^j 分别为 x_i^j 的上、下限。

其对应准反向解为

$$\hat{x}_i^j = \begin{cases} \text{rand}(\text{avg}_i^j, \hat{x}_i^j) & x_i^j \leq \text{avg}_i^j \\ \text{rand}(\hat{x}_i^j, \text{avg}_i^j) & x_i^j > \text{avg}_i^j \end{cases} \quad (13)$$

其中: $\text{avg}_i^j = \frac{b_i^j - a_i^j}{2}$; (a, b) 为 a, b 之间的随机数。

将 N 个初始个体和准反向学习求得的 N 个反向解合并, 利用种群多样性最大化筛选机制, 从 $2N$ 个个体中选择种群多样性最大化的 N 个个体。为获得较好的初始化种群, 对任意解和对应的准反向解进行优化处理, 这样既能保证数据的多样性, 同时又能尽快收敛到最优解^[21]。

2) 非线性收敛因子。传统 WOA 算法中搜索目标阶段数学模型为

$$\begin{cases} D = |CX_p(t) - X(t)| \\ X(t+1) = X_p(t) - AD \end{cases} \quad (14)$$

其中: t 为当前迭代次数; $X(t)$ 为个体位置; $X_p(t)$ 为当前最优解; A, C 为常数。

$$\begin{cases} A = 2ar_1 - a \\ C = 2r_2 \end{cases} \quad (15)$$

其中: r_1, r_2 分别为 $[0, 1]$ 的随机数; a 为控制参数。

WOA 算法的全局搜索能力和局部开发能力不足, 对参数 $|A|$ 进行调整, 可以平衡两者的搜索能

力。当 $|A| > 1$ 时,算法以0.5的概率全局搜索;当 $|A| < 1$ 时,算法进行局部开发^[22]。

传统WOA算法的寻优过程极为复杂,控制参数 a 线性递减策略不能适应寻优过程的实际情况,可能会导致收敛精度不高或易陷入局部最优。因此,在设计收敛因子 a 时,应考虑在搜索前期以较小的值随迭代次数增大而递增,当增大到一个较大值后,再快速递减到一个较小值,最后以较慢的速度再递增。笔者提出一种随进化迭代次数而非线性变化的收敛因子更新公式

$$a = 2 - 2\sin\left(\mu \frac{t}{\max_iter} \pi + \varphi\right) \quad (16)$$

其中: $\max_iter$ 为最大迭代次数; t 为当前迭代次数; μ 和 φ 为常数,分别取为 $\mu = 0.5$, $\varphi = 0$ 。

3) 自适应权重策略与随机差分变异策略。为避免WOA算法陷入过拟合,引入自适应权重策略,使权重不再取固定值,而是根据适应度的大小随机调整权值,使鲸鱼在搜寻猎物过程中更加多样化。其具体表达式为

$$\omega = 1 - \left(\frac{t}{l \max_iter} - 1 \right) / (e - 1) \quad (17)$$

$$X(t+1) = \omega X_p(t) - AD = \omega X_p(t) + De^{bl} \cos(2\pi l) \quad (18)$$

为更好地解决传统WOA算法易陷入局部最优的问题,引入变异操作,以增强群体的多样性并跳出局部最优。常用的变异操作有均匀变异、多样性变异、高斯变异和柯西变异等^[23]。本研究采用一种新的变异策略,即随机差分变异策略。利用当前鲸鱼个体、当前最优个体和在群体中随机选择的鲸鱼个体进行随机差分,产生新的个体。具体表达式为

$$X(t+1) = r_1(X_p(t) - X(t)) + r_2(X'(t) - X(t)) \quad (19)$$

其中: r_1, r_2 为 $[0, 1]$ 的随机数; $X'(t)$ 为种群中随机选取的个体。

基于改进的WOA算法,每个个体进行第1阶段和第2阶段时采用自适应权重策略去更新位置,之后通过随机差分变异策略再次更新,取变换前后的最优位置,加快收敛,有效避免了种群陷入过拟合以及局部最优状态。

2.3 改进WOA-SVM模型

由于 C 和 g 两参数的选择不同,故障诊断精度也不同,且传统WOA算法存在精度低、速度慢和易陷入局部最优等缺点,因此引入改进WOA算法,对

SVM参数进行联合寻优。寻优步骤如下:

1) 设定鲸鱼数量为20,最大迭代次数为50,参数 C 和 g 的搜索范围分别为 $[0, 500]$ 和 $[0, 200]$,利用准反向学习得到优化后的初始化种群;

2) 计算每个个体的适应度值,并记录最优个体和位置;

3) 引入非线性因子 a ,根据式(16)更新 A 和 C ,由 $|A|$ 控制鲸鱼进行全局搜索还是局部搜索;

4) 利用概率 p 判别鲸鱼执行的更新方式,当 $p \geq 0.5$ 时根据式(18)更新个体位置,当 $p < 0.5$ 时根据 $|A|$ 值进行判断,当 $|A| < 1$ 时根据式(14)更新个体位置,当 $|A| \geq 1$ 时根据式(17)更新个体位置;

5) 根据式(19)对种群添加随机差分变异扰动,判断是否到达最大迭代次数,输出优化后的 C 和 g ,寻优结束。

基于改进WOA-SVM的故障诊断流程见图1。




图1 基于改进WOA-SVM的故障诊断流程

Fig.1 Fault diagnosis process based on improved WOA-SVM

2.4 变压器故障诊断模型

首先,模拟变压器的6种典型故障,采集不同工况下的振动信号,将所得振动信号进行预处理,包括异常值处理、缺失值补充和归一化处理;其次,将预处理后的数据利用SSWT进行二维时频分析,得到相应的二维时频图,初步观察其特征,再利用GLCM方法提取其对应的特征,输入SVM中进行故障

分类;然后,针对其他算法中存在的求解精度低、收敛速度慢和易陷入局部最优的缺点,提出改进WOA算法优化SVM;最后,经过和原始WOA-SVM,PSO-SVM,GWO-SVM进行对比,得到最终分析结果。基于SSWT-GLCM与改进WOA-SVM故障诊断流程如图2所示。

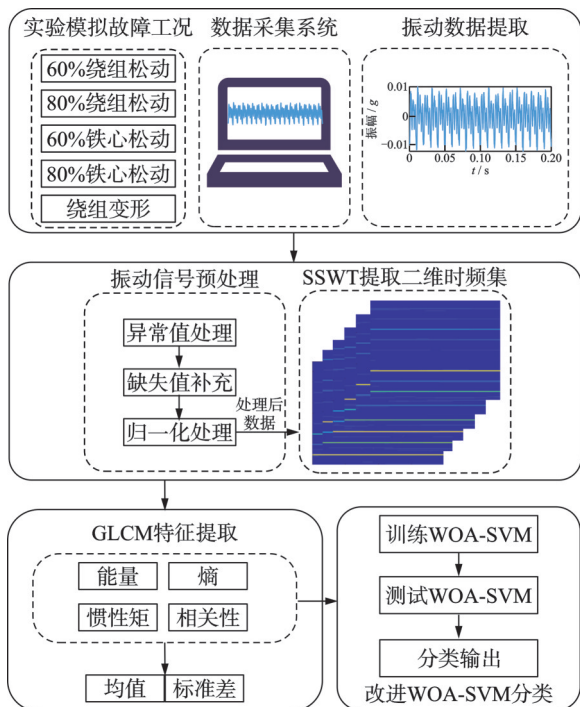


图2 基于SSWT-GLCM与改进WOA-SVM故障诊断流程
Fig.2 Fault diagnosis process based on SSWT-GLCM and improved WOA-SVM

3 变压器各故障类型振动信号分析

采用一台电压等级为10 kV的单相油浸式变压器为对象进行实验分析。在实验中,铁心由前后两个夹片固定,绕组用垫块支撑并压紧,利用循环电流法进行负载实验,分别采集变压器正常状态、绕组松动、铁心松动和绕组变形4种工况下的振动信号。实验所用振动传感器的型号为AD100T,灵敏度为100 mV/g,振动信号采集系统采用东华DHDAS振动信号采集仪。变压器振动传感器位置分布图如图3所示,其中 x_1, x_2, x_3 分别为3个传感器所贴位置。

实验主要研究变压器可能产生的3种故障类型。为模拟故障程度,采用力矩扳手扭动螺栓,并记录力矩值。针对绕组松动、铁心松动两种工况,采用力矩扳手调整绕组拉杆和穿心螺栓,使其分别为额定预紧力的60%和80%。绕组松动是通过锤子敲击的方式,使其形变位移为0.5 cm。典型机械故障模拟如图4所示。




图3 变压器振动传感器位置分布图

Fig.3 Transformer vibration sensor position distribution




图4 典型机械故障模拟

Fig.4 Typical mechanical fault simulation

由于变压器铁心旁厄处振动变化较为明显,因此取 x_3 测点数据进行分析。截取 x_3 测点所测得的1 s内6种工况下变压器箱体振动信号时域波形,如图5所示。可以发现,在不同工况下油浸式变压器箱体振动信号存在差异,但仅凭此无法实现变压器的故障诊断,于是将箱体振动信号映射到时频域,利用SSWT-GLCM提取其时频域上的特征,利用改




图5 变压器箱体振动信号时域波形

Fig.5 Time domain waveform of transformer box vibration signal

进的 WOA-SVM 算法实现故障分类。

4 变压器故障特征提取与分类

4.1 SSWT 变压器故障特征分析

分别利用 CWT,STFT,ST 和 SSWT 对振动信号进行时频分析,正常工况下振动信号二维时频图如图 6 所示。由图可知:CWT 得到的变压器箱体振动信号时频图中能量泄露较大,频带交叉混叠且各频率频带过宽,无法得到清晰的时频分析结果;ST-FT 得到的结果高频部分能量较为集中,而在低频部分依旧存在频带交叉与涂抹现象,无法清晰分辨结果;ST 可以基本区分各频带信号,但存在端点效应;SSWT 能量堆叠密集,各频带中心能量值高,能够有效区别各频率分量。实验结果进一步说明,与现有方法相比,SSWT 更适用于变压器箱体振动信号的二维时频分析,更有利于提高变压器箱体振动信号的故障诊断精度。




图 6 正常工况下振动信号二维时频图
Fig.6 Two dimensional time-frequency diagram of vibration signal under normal working conditions

图 7 为基于 SSWT 分析的典型机械故障振动信号时频图。正常工况时变压器基本以 100 Hz 为主频运行;当变压器出现绕组或铁心松动时,高频分量明显增加且一直存在;而出现绕组变形时,会出现 600,700 和 900 Hz 的高频分量,500 和 800 Hz 谐波出现后又消失,这将导致变压器损耗增加,严重影响变压器的运行寿命。利用变压器箱体振动信号获取的二维时频图进行故障分类,可以获取变压器目前的运行状态,及时做出调整,对延长变压器寿命及电

力系统稳定运行有重大意义。




图 7 基于 SSWT 分析的典型机械故障振动信号时频图
Fig.7 Time-frequency diagram of analyzing vibration signal of typical mechanical fault based on SSWT

4.2 GLCM 变压器故障特征提取

GLCM 提取的 4 个特征(能量、熵、对比度和相关性)在 θ 选取不同值时是不同的,且随着距离 d 的变化而变化。因此,随着 d 的变化所计算出的特征在任何角度都不是恒定的。根据变压器振动时频图,笔者选取 $d=1, \theta=0^\circ$ 作为主方向,最大灰度值 G 设置为 16,对 GLCM 参数进行设定。

以测点 x_3 处的振动信号为例,首先,采集 6 种故障工况共计 270 个样本,采样时间为 1 s,并利用 SSWT 对样本进行时频分析,选择其中 180 个样本作为训练集,剩余 90 个样本作为测试集;其次,利用 GLCM 分析二维时频图的图像特征信息,产生 8 个特征。GLCM 提取故障特征结果见图 8。

由图可知,GLCM 可以有效提取二维时频图的图像特征信息,反映出变压器不同故障状态下相关的动态特性,具有良好的类内聚集性和类间离散性,可较准确地识别不同故障工况,为后续建立的变压器故障诊断模型提供有效的特征参数。




图8 GLCM提取故障特征结果

Fig.8 GLCM extracts fault feature results

4.3 变压器故障分类结果比较

为了实现变压器多种故障状态智能识别,将利用SSWT-GLCM所提取的变压器振动信号低维特征矩阵转化为特征向量后输入到SVM算法中,建立变压器故障状态识别模型。其中,SVM的惩罚参数 C 和核函数参数 g 寻优范围为 $[2^{-10}, 2^{10}]$,搜索路径为 $2^{-10+0.2n}$ (n 为整数)。SVM样本数据集由变压器6种不同工况下的振动信号构成,实验数据集分类如表2所示。

表2 实验数据集分类

Tab.2 Classification of experimental data sets

运行状态	状态编号	训练集数	测试集数
60% 绕组松动	1	30	15
60% 铁心松动	2	30	15
80% 绕组松动	3	30	15
80% 铁心松动	4	30	15
绕组变形	5	30	15
正常	6	30	15

在改进WOA-SVM故障诊断识别模型的建立过程中,特征矩阵的迭代次数不同,识别效果也不同。为确定合理的迭代次数,寻取最优化的参数 C 和 g ,设置迭代次数 G 为50。改进WOA-SVM适应度曲线如图9所示。由图可知:当迭代次数较小时,

识别模型具有较低的识别精度,表明该特征矩阵并未充分保留原图像局部特征,部分特征信息丢失;随着 G 逐渐增大,识别精度逐渐提高,当 G 为30左右时达到最佳,此时时频图信息被充分挖掘;当 G 值继续增大,计算精度基本趋于稳定,而由于计算量和信息冗余的大量增加,导致计算速度变慢。考虑到SVM识别模型的识别精度和运算效率,参数 G 取30最佳。




图9 改进WOA-SVM适应度曲线

Fig.9 Improved WOA-SVM fitness curve

当 $G=30$ 时,参数 C 和 g 的寻优结果分别为1.319 5, 0.001 7。改进WOA-SVM, WOA-SVM, PSO-SVM和GWO-SVM的分类结果分别由图10~13所示。由故障分类结果可知:未改进的WOA算法和PSO算法优化的SVM对于60%绕组、80%绕组以及绕组变形之间的区分存在明显不足,识别准确率仅为82%和80%;GWO算法优化的SVM提高了对绕组变形的区分能力,但仍没有解决60%绕组和80%绕组的识别准确率过低的问题;改进WOA算法优化的SVM对60%绕组、80%绕组以及绕组变形的区分准确度都有了明显的提高,总体识别准确率可达93%。

为进一步说明本研究所提的改进WOA-SVM算法的有效性,将其分别应用于另外两测点 x_1 和 x_2 ,并与其他方法进行对比。变压器故障状态识别结果对比如表3所示。由表可知:传统算法具有较高的运算效率,但是识别精度较低;本研究所建立的故障




图10 改进WOA-SVM分类结果

Fig.10 Improved WOA-SVM classification results




图11 WOA-SVM分类结果

Fig.11 WOA-SVM classification results




图12 PSO-SVM分类结果

Fig.12 PSO-SVM classification results




图13 GWO-SVM分类结果

Fig.13 GWO-SVM classification results

诊断模型可以在保证识别精度的情况下快速识别特征参数,变压器故障识别率保持在 93% 左右,诊断时间在 5.5 s 左右,较其他方法具有较高的识别精度和运算效率。同时,改进 WOA-SVM 识别率标准差为 0.451 5, WOA-SVM, PSO-SVM 和 GWO-SVM 所对应的识别率标准差分别为 1.402 5, 1.049 1 和 1.361 1,可见所提出的改进 WOA-SVM 算法具有良好的鲁棒性,使诊断精度维持在一个较高水平。

表 3 变压器故障状态识别结果对比
Tab.3 Comparison of transformer fault state identification results

测点	处理方法	训练时间/s	识别率/%
x_1	改进 WOA-SVM	5.56	93.36
	WOA-SVM	5.49	87.33
	PSO-SVM	8.33	80.11
	GWO-SVM	4.78	84.18
x_2	改进 WOA-SVM	5.83	92.71
	WOA-SVM	6.42	86.27
	PSO-SVM	6.31	88.56
	GWO-SVM	4.21	80.87
x_3	改进 WOA-SVM	5.16	93.33
	WOA-SVM	5.13	82.22
	PSO-SVM	7.23	80.00
	GWO-SVM	5.21	86.66

5 结 论

1) 利用 SSWT 算法提取油浸式变压器箱体振动信号的二维时频图,能够有效解决因信号时频分析中能量泄露、信息遗失、宽频模糊和频带混叠等导致的故障识别率低的问题,该方法可以有效保留其主要特征信息,得到能量堆叠密集的二维时频图。

2) 利用 SSWT-GLCM 纹理特征提取的方法可有效提取二维时频图的图像特征信息,反映变压器不同故障状态下的相关动态特性,有良好的类内聚集性和类间离散性,可较准确地识别不同故障工况。

3) 改进 WOA-SVM 的变压器机械故障时频诊断模型可显著提高变压器故障诊断的效果,改善了传统 WOA 易陷入局部最优的不足,具有良好的寻优能力。改进 WOA-SVM 算法较传统 WOA-SVM, PSO-SVM 和 GWO-SVM 有更好的识别效果,可以在保证识别精度的情况下快速识别特征参数,总体诊断准确率保持在 93% 左右,且具有良好的鲁棒性。

参 考 文 献

[1] 张九思, 马宏忠, 李勇, 等. 基于 VMD 的变压器绕组松动故障分析与诊断[J]. 高压电器, 2021, 57(8): 198-208.
ZHANG Jiusi, MA Hongzhong, LI Yong, et al. Analysis and diagnosis on looseness of transformer winding based on VMD [J]. High Voltage Apparatus, 2021, 57(8): 198-208.(in Chinese)

[2] 刘云鹏, 董王英, 许自强, 等. 基于卷积神经网络的变压器套管故障红外图像识别方法[J]. 高压电器, 2021, 57(10): 134-140.
LIU Yunpeng, DONG Wangying, XU Ziqiang, et al. Infrared image recognition method on fault of transformer bushing based on convolutional neural networks [J]. High Voltage Apparatus, 2021, 57(10): 134-140.(in Chinese)

[3] 梁永亮, 郭汉琮, 薛永端. 基于特征气体关联特征的变压器故障诊断方法[J]. 高电压技术, 2019, 45(2): 386-392.
LIANG Yongliang, GUO Hancong, XUE Yongduan. Transformer fault diagnosis method based on association characteristics of characteristic gases [J]. High Voltage Engineering, 2019, 45(2): 386-392.(in Chinese)

[4] LI F, LUO Y. Total focusing method damage imaging in frequency domain using laser-ultrasonic lamb wave based on time-domain filtering in multi-band [J]. Acta Mechanica Solida Sinica, 2021, 34(3): 404-424.

[5] 赵仲勇, 姚陈果, 李成祥, 等. 基于短时 Fourier 变换的变压器绕组变形脉冲频率响应曲线获取方法[J]. 高电压技术, 2016, 42(1): 241-247.
ZHAO Zhongyong, YAO Chenguo, LI Chengxiang, et al. Method for obtaining the impulse frequency response curves of power transformer winding deformation based on short time fourier transform [J]. High Voltage Engineering, 2016, 42(1): 241-247.(in Chinese)

[6] WU S D, WU C W, LIN S G, et al. Time series analysis using composite multiscale entropy [J]. Entropy, 2013, 15(3): 1069-1084.

[7] 翁汉琨, 李昊威, 邢家维, 等. 采用 S 变换相位差及能量相对熵的换流变零序差动保护新判据[J]. 电力自动化设备, 2019, 39(9): 20-26.
WENG Hanli, LI Haowei, XING Jiawei, et al. Novel criterion adopting S-transform phase angle difference and energy relative entropy for zero-sequence differential protection of converter transformer [J]. Electric Power Automation Equipment, 2019, 39(9): 20-26.(in Chinese)

[8] HUANG S L, SUN H Y, WANG S, et al. SSWT and VMD linked mode identification and time-of-flight extraction of denoised SH guided waves [J]. IEEE Sensors Journal, 2021, 21(13): 14709-14717.

- [9] 余长厅,黎大健,汲胜昌,等.基于振动噪声及BP神经网络的变压器故障诊断方法研究[J].高压电器,2020,56(6):256-261.
YU Changting, LI Dajian, JI Shengchang, et al. Research on transformer fault diagnosis method based on vibration noise and BP neural network[J]. High Voltage Apparatus, 2020, 56(6): 256-261.(in Chinese)
- [10] 李中,张卫华,孙娜,等.基于广义回归神经网络的变压器表面振动基频幅值计算[J].高电压技术,2017,43(7):2287-2293.
LI Zhong, ZHANG Weihua, SUN Na, et al. Calculation of vibration fundamental frequency amplitude of transformer surface based on generalized regression neural network[J]. High Voltage Engineering, 2017, 43(7): 2287-2293.(in Chinese)
- [11] 石鑫,朱永利,宁晓光,等.基于深度自编码网络的电力变压器故障诊断[J].电力自动化设备,2016,36(5):122-126.
SHI Xin, ZHU Yongli, NING Xiaoguang, et al. Transformer fault diagnosis based on deep auto-encoder network[J]. Electric Power Automation Equipment, 2016, 36(5): 122-126.(in Chinese)
- [12] 张义文,冯斌,陈页,等.基于遗传算法优化XGBoost的油浸式变压器故障诊断方法[J].电力自动化设备,2021,41(2):200-206.
ZHANG Youwen, FENG Bin, CHEN Ye, et al. Fault diagnosis method for oil-immersed transformer based on XGBoost optimized by genetic algorithm[J]. Electric Power Automation Equipment, 2021, 41(2): 200-206.(in Chinese)
- [13] SOTO A R E, LIMA S L, SAAVEDRA O R. Incipient fault diagnosis in power transformers by DGA using a machine learning ANN - mean shift approach [C] //2019 IEEE International Autumn Meeting on Power, Electronics and Computing (ROPEC). Ixtapa, Mexico:IEEE, 2019: 1-6.
- [14] 刘云鹏,许自强,李刚,等.人工智能驱动的数据分析技术在电力变压器状态检修中的应用综述[J].高电压技术,2019,45(2):337-348.
LIU Yunpeng, XU Ziqiang, LI Gang, et al. Review on applications of artificial intelligence driven data analysis technology in condition based maintenance of power transformers[J]. High Voltage Engineering, 2019, 45(2): 337-348.(in Chinese)
- [15] 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):171-178.
AN Guoqing, SHI Zhewen, MA Shifeng, et al. Fault diagnosis of WOA-SVM transformer based on RF feature optimization[J]. High Voltage Apparatus, 2022, 58(2): 171-178.(in Chinese)
- [16] WU Y H, SUN X B, YANG P F, et al. Transformer fault diagnosis based on improved particle swarm optimization to support vector machine[J]. Journal of Physics: Conference Series, 2021, 1750(1): 12-74.
- [17] HUANG X Y, HUANG X L, WANG B R, et al. Fault diagnosis of transformer based on modified grey wolf optimization algorithm and support vector machine[J]. IEEJ Transactions on Electrical&Electronic Engineering, 2020, 15(3): 409-417.
- [18] 余松,胡东,唐超,等.基于TLR-ADASYN平衡化数据集的MSSA-SVM变压器故障诊断[J].高电压技术,2021,47(11):3845-3853.
YU Song, HU Dong, TANG Chao, et al. MSSA-SVM transformer fault diagnosis method based on TLR-ADASYN balanced data set[J]. High Voltage Engineering, 2021, 47(11): 3845-3853.(in Chinese)
- [19] MIAO Y H, ZHAO M, MAKIS V, et al. Optimal swarm decomposition with whale optimization algorithm for weak feature extraction from multicomponent modulation signal[J]. Mechanical Systems and Signal Processing, 2019, 122: 673-691.
- [20] 郑直,张华钦,潘月.基于改进鲸鱼算法优化LSTM的滚动轴承故障诊断[J].振动与冲击,2021,40(7):274-280.
ZHENG Zhi, ZHANG Huaqin, PAN Yue. Rolling bearing fault diagnosis based on IWOA-LSTM[J]. Journal of Vibration and Shock, 2021, 40(7): 274-280.(in Chinese)
- [21] 赵书涛,王紫薇,陈志华,等.有载分接开关GLCM纹理特征及改进随机森林算法的故障诊断方法[J].高电压技术,2022,48(9):3593-3601.
ZHAO Shutao, WANG Ziwei, CHEN Zhihua, et al. GLCM texture features of on-load tap changer and fault diagnosis method based on improved random forest algorithm[J]. High Voltage Engineering, 2022, 48(9): 3593-3601.(in Chinese)
- [22] LIM D, XU G H, LAI Q, et al. A chaotic strategy-based quadratic opposition-based learning adaptive variable-speed whale optimization algorithm[J]. Mathematics and Computers in Simulation, 2022, 193: 71-99.
- [23] MANDAVI S, RAHNAMAYAN S, DEB K, et al. Opposition based learning: a literature review[J]. Swarm & Evolutionary Computation, 2018, 30(2): 12-13.



第一作者简介:杨义,男,1995年12月生,硕士生。主要研究方向为电力设备在线监测与故障诊断。
E-mail:1026170202@qq.com