

DOI: 10.13382/j.jemi.B2104980

基于多尺度熵分析与改进 SVM 的变压器故障识别*

邵凯旋 何怡刚 汪磊

(武汉大学电气与自动化学院 武汉 430072)

摘要:为解决传统变压器故障识别方法提取故障特征难度大、识别准确率低等问题,提出基于多尺度标准差模糊熵(SDMFE)和哈里斯鹰算法(HHO)优化支持向量机(SVM)的故障识别方法。首先,采用基于模糊熵的多尺度分析量化变压器振动信号复杂的动态特性,提取多时间尺度下的故障特征。随后,将利用SDMFE获得的故障特征输入SVM分类器识别变压器不同的故障。同时,为了提升SVM的识别性能,引入HHO算法以自适应、准确地选择SVM参数。最后,利用变压器实测振动信号进行了对比试验。与不同的信息熵、不同的优化策略和不同的分类器相比,所提方法取得98.56%的最高识别准确度和最好的识别稳定性。结果表明所提方法能够有效提取故障敏感特征和准确识别变压器故障状态。

关键词: 变压器故障识别;多尺度标准差模糊熵;支持向量机;哈里斯鹰优化算法

中图分类号: TM407 **文献标识码:** A **国家标准学科分类代码:** 470.40

Fault identification of transformer based on multiscale entropy analysis and improved SVM

Shao Kaixuan He Yigang Wang Lei

(School of Electrical Engineering and Automation, Wuhan University, Wuhan 430072, China)

Abstract: To handle the problems of difficulty in extracting fault features and low identification accuracy of traditional transformer fault identification methods, a novel identification method is proposed by fusing standard deviation-based multiscale fuzzy entropy (SDMFE) and Harris hawks algorithm (HHO) optimized support vector machine (SVM). Firstly, multiscale analysis method based on fuzzy entropy is employed to quantify the complex dynamic characteristics of transformer vibration signals, and then extract fault features under multi-time scales. Subsequently, the fault features obtained by SDMFE are input into SVM for identifying transformer different faults. At the same time, to improve SVM recognition performance, an optimization strategy integrating HHO algorithm is introduced to select SVM parameters adaptively and accurately. Finally, a comparative experiment is carried out using the measured vibration signal of the transformer. Compared with different information entropies, different optimization strategies and different classifiers, the proposed method achieves the highest identification accuracy of 98.56% and identification stability. The results show that the proposed method can effectively extract fault sensitive features and accurately identify transformer fault status.

Keywords: transformer fault identification; SDMFE; HHO; SVM

0 引言

变压器是电网的核心和重要设备,用于连接不同电

压等级的输电系统。由于在各种气候条件以及不同的电气和机械条件下使用,变压器在运行过程中不断面临着巨大的危险,会导致绕组和铁芯等部件故障,并给电网带来巨大的影响^[1]。因此,监测变压器的健康状态和准确

收稿日期: 2021-12-04 Received Date: 2021-12-04

* 基金项目:国家重点研发计划“智能电网技术与装备”专项“电力物联网关键技术”项目(2020YFB0905905)、国家重点研发计划“重大科学仪器设备开发”项目(2016YFF0102200)、国家自然科学基金(51977153, 51977161, 51577046)、中央高校基本科研业务费专项资金(2042021k0233)、国家自然科学基金重点项目(51637004)、装备预先研究重点项目(41402040301)、湖北省重点研发计划项目(2021BEA162)、武汉市局科技计划项目(20201G01)资助

地识别故障有助于最大限度地减少设备损坏、经济损失和对电力系统可靠性的影响。

目前,针对变压器故障识别与诊断提出了多种方法,主要有短路阻抗法^[2]、频响分析法(frequency response analysis, FRA)^[3]和溶解气体分析法(dissolved gas analysis, DGA)^[4]。短路阻抗法是一种离线检测方法,通过变压器绕组的短路阻抗来有效检测变压器绕组变形和铁芯位移等故障。然而,离线检测需将变压器退出运行状态,增加停电带来的风险,且难以应对电网在线检测的趋势。FRA 虽利用变压器的频率响应特性可以快速检测到绕组和铁芯变形的严重程度及位置,但其应用时需与电网进行电气连接,操作复杂繁琐,影响故障检测识别的效率。DGA 方法通过分析油内溶解的气体,检测识别变压器内部放电、受潮和过热等异常状况,但如果溶解气体浓度释放不充分,基于 DGA 的故障识别效果在一定程度上受到影响。

变压器内部发生故障时最直接的表现形式是机械振动。因此,变压器的振动信号包含了大量关于变压器运行状态的信息,基于振动信号分析的变压器状态识别得到广泛应用^[5-6]。通过在变压器外壁布置传感器采集振动信号,并对信号进行分析和获取与故障有关的信息,进而识别相应的故障。然而,当前的文献研究集中在对变压器内部绕组与铁芯松动和形变程度等机械故障的识别^[7-8],对不同励磁激励下变压器的动态响应和匝间短路的故障识别研究并不充分。事实上,变压器欠励磁和过励磁是变压器中较为常见的不良运行状态,可能会增加变压器铁心损耗,引起意外发热。变压器绕组匝间短路一般由于绝缘损坏造成线匝短接,会导致变压器烧毁。因此,有必要对变压器不同励磁状态下的异常状况和绕组匝间短路故障进行有效识别。

然而,由于振动传输路径长,且受到变压器其他部件的干扰,测量的振动信号表现出强烈的非平稳性。因此,如何从非平稳振动信号中提取有价值的故障信息仍是一项具有挑战和热门的课题。基于时域和频域的方法,如峭度^[9]、小波变换^[10]等,难以深度提取有代表性的故障特征,全面刻画故障演化的动态特性。为解决此问题,本文以非线性动力学的视角,提出基于标准差的多尺度模糊熵(standard deviation-based multiscale fuzzy entropy, SDMFE)^[11]用于量化变压器故障的动态变化,结合二阶矩标准差多尺度过程从多个时间尺度下分析非平稳信号,挖掘深层次多元故障特征。当变压器内部发生故障时,振动响应在幅值和频率分布上发生变化直接影响熵值的变化。同时,基于熵的方法不依赖于人工经验和变压器的容量大小、负载大小和故障频率等相关先验信息,可以有效检测和识别变压器的故障。

构建合适的分类器,并根据提取的故障特征识别不

同的故障,是实现变压器故障准确识别的重要环节。对于变压器的不同故障,获取的故障样本通常是不充足的,这形成一个高维和小样本的问题。在这种情况下,支持向量机(support vector machine, SVM)具有良好的泛化能力,并且由于其较好的小样本学习能力,可以提供更可靠的结果^[12]。因此,本文选择 SVM 作为分类器用于处理高维小样本的变压器故障样本。然而,SVM 的分类性能受到其参数的显著影响。为此,文献中设计了一些经典的方法来选择合适的参数,如网格搜索(grid search, GS)^[13]、粒子群优化(particle swarm optimization, PSO)^[14]。然而,GS 需要在解空间内划分网格,进行大量的搜索,运行效率和解的质量与网格大小有很大关系。PSO 需要设置许多参数,影响其搜索性能,极易陷入局部最优解。哈里斯鹰优化算法(Harris hawks optimization, HHO)是近年提出的一种新式元启发群智能算法,通过较少的参数设置可以实现更好的局部搜索和全局搜索,获取高质量的解^[15]。受前人研究的启发,本文提出 HHO 与 SVM 深度融合的优化策略,克服 GS 和 PSO 存在的不足,以更有效的方式优化 SVM 的参数,从而建立 HHO-SVM 的变压器故障识别模型。

基于 SDMFE、HHO 和 SVM 的上述优点,提出了一种新的变压器故障识别方法。为了验证所提方法的有效性和优越性,利用变压器实测信号进行了 3 组对比实验:不同信息熵的对比、不同优化策略的对比和不同分类器的对比。对比结果表明,该方法能够提取显著的故障特征和有效识别不同的故障状态,为变压器故障特征提取和故障识别提供了一种新的思路。

1 研究方法

1.1 多尺度标准差模糊熵

通过引入基于标准差的粗粒化方法,SDMFE 定义为不同尺度下的模糊熵值,主要的计算步骤如下。

1) 给定长度为 N 的时间序列 $\{x(b), b = 1, 2, \dots, N\}$, 根据粗粒化过程生成多个子序列:

$$y_i^{(\tau)} = \sqrt{\frac{1}{\tau} \sum_{b=(i-1)\tau+1}^{\tau} (x_b - \bar{x}_i^{(\tau)})^2}, 1 \leq i \leq \lfloor \frac{N}{\tau} \rfloor = M$$

$$\bar{x}(\tau)_i = \frac{1}{\tau} \sum_{b=(i-1)\tau+1}^{\tau} x_b, \tau = 2, 3, \dots \quad (1)$$

其中, τ 是尺度因子; $\lfloor \cdot \rfloor$ 为向下取整运算; 当 $\tau = 1$ 时, $y_i^{(1)}$ 为原始序列; 当 $\tau > 1$ 时, 原始序列被分成 τ 个新的长度为 M 的子序列 $\{y_i^{(\tau)}\}$ 。

2) 利用一个嵌入参数 m 获得新的序列:

$$U_t^m = \{y(t), y(t+1), \dots, y(t+m-1)\} - y_0(t)$$

$$y_0(t) = \sum_{j=0}^{m-1} \frac{y(t+j)}{m}, t = 1, 2, \dots, M - m + 1 \quad (2)$$

3) 对于每个 U_i^m , 计算每个元素 $U_{t_1}^m$ 和 $U_{t_2}^m$ 的切比雪夫距离:

$$d_{t_1 t_2} = d[U_{t_1}^m, U_{t_2}^m] = \max_{0 \leq k \leq m-1} |y(t_1 + k) - y(t_2 + k)| : t_1 \neq t_2 \quad (3)$$

4) 给定一个模糊边界 n 和容限 r , $U_{t_1}^m$ 和 $U_{t_2}^m$ 的相似度 $D_{t_1 t_2}^m$ 由模糊函数 $f(d_{t_1 t_2}, n, r)$ 决定:

$$D_{t_1 t_2}^m(n, r) = f(d_{t_1 t_2}, n, r) = \exp(-(d_{t_1 t_2})^n / r) \quad (4)$$

5) 定义一个函数 ϕ^m :

$$\phi^m(y, n, r) = \frac{1}{M - m} \sum_{t_1=1}^{N-m} \frac{1}{M - m - 1} \sum_{t_2=1, t_1 \neq t_2}^{N-m} D_{t_1 t_2}^m(n, r) \quad (5)$$

6) 对于 $m+1$, 重复上述步骤 1)~5) 获得新的函数 ϕ^{m+1} 。

7) 根据条件熵, 计算 SDMFE 的值:

$$SDMFE^{(T)}(m, n, r, x) = \ln \phi^m(n, r, x) - \ln \phi^{m+1}(n, r, x) \quad (6)$$

1.2 支持向量机

SVM 利用核函数将非线性输入样本映射到高维空间中, 并在该空间通过全局搜索构建最优超平面, 进而实现对样本的分类。设训练样本集为 V , $V = \{(x_1, y_1), (x_2, y_2), \dots, (x_l, y_l)\}$, 其中 $x_i \in \mathbf{R}^l$ 为输入特征, y_i 为分类标签。最优超平面的构建转化为求解二次规划问题, 目标函数和约束条件为:

$$\min \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^l \xi_i \quad (7)$$

$$\text{s. t. } y_i(\mathbf{w} \cdot x_i + b) \geq 1 - \xi_i, i = 1, 2, \dots, l$$

其中, \mathbf{w} 是权重矩阵; b 为偏置参数; ξ_i 为松弛项; C 为惩罚因子。采用核函数 $K(x, x_i)$ 实现线性可分。由于径向基函数(radial basis function, RBF)优良的特性, 本文采用 RBF 函数用作支持向量机的核函数。引入拉格朗日算子, 最优分类的超平面决策函数可表示为:

$$f(x) = \text{sgn}\left(\sum_{i=1}^n a_i K(x_i, x) + b\right) \quad (8)$$

1.3 哈里斯鹰优化算法

HHO 是最近提出的一种受自然启发的智能算法, 具有较少的参数设置和更好的搜索能力, 它从数学上模拟了哈里斯鹰的狩猎行为。HHO 算法可以解决现实世界中的许多复杂优化问题, 其整体算法过程示意图如图 1 所示, 包括探索和利用两个阶段。

在探索阶段, 将鹰群的捕猎行为建模为:

$$X^{l+1} = \begin{cases} X_{rand}^l - r_1 |X_{rand}^l - 2r_2 X^l|, \\ q \geq 0.5 \\ (X_{prey}^l - X_m^l) - r_3(LB + r_4(UB - LB)), \\ q < 0.5 \end{cases} \quad (9)$$

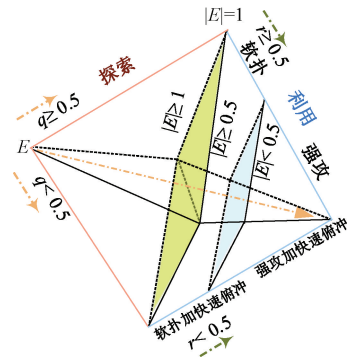


图 1 HHO 算法整体过程

Fig. 1 Scheme of the overall process of HHO

其中, X^{l+1} 为下一次迭代鹰群的位置; X_{prey}^l 为猎物的位置; X^l 为当前鹰群的位置; X_{rand} 为从当前鹰群中随机选择一个哈里斯鹰的位置; r_1, r_2, r_3, r_4 和 q 为 $(0, 1)$ 的随机数; LB 和 UB 为变量的下限和上限; X_m^l 为当前鹰群的平均位置; X_i 表示第 i 个鹰的位置; N 为哈里斯鹰的数量。

利用式 (10) 实现从探索过渡到利用阶段:

$$E = 2E_0 \left(1 - \frac{l}{l_{max}}\right) \quad (10)$$

其中, l_{max} 为最大迭代次数; E_0 表示猎物的初始能量。猎物的能量 E 在 -1 和 1 之间。哈里斯鹰根据猎物的能量 E 的变化调整狩猎方式。

利用阶段包含 4 个捕猎策略: 软扑、强攻、软扑加快速俯冲、强攻加快速俯冲。

1) 软扑策略为:

$$X^{l+1} = X_{prey}^l - E |J X_{prey}^l - X^l| \quad (11)$$

其中, $J = 2(1-r)$, r 为 $0 \sim 1$ 之间的随机数。

2) 强攻策略为:

$$X^{l+1} = X_{prey}^l - E |X_{prey}^l - X^l| \quad (12)$$

3) 软扑加快速俯冲策略为:

$$\begin{aligned} Y_1 &= X_{prey}^l - E |J X_{prey}^l - X^l| \\ Z_1 &= Y_1 + S \times LF(D) \end{aligned} \quad (13)$$

$$X^{l+1} = \begin{cases} Y_1, & F(Y_1) < F(X^l) \\ Z_1, & F(Z_1) < F(X^l) \end{cases}$$

其中, D 为待优化问题的维度; S 为 $1 \times D$ 的随机矩阵。LF 为 Levy 飞行函数, 其表达式为:

$$LF(x) = 0.01 \times \frac{u \times \sigma}{|v|^{1/\beta}} \quad (14)$$

$$\sigma = \left(\frac{\Gamma(1 + \beta) \times \sin\left(\frac{\pi\beta}{2}\right)}{\Gamma\left(\frac{1 + \beta}{2}\right) \times \beta \times 2\left(\frac{\beta - 1}{2}\right)} \right)^{\frac{1}{\beta}}$$

其中, u 和 v 是 $0 \sim 1$ 的随机数; 依文献 [13] 设定, $\beta = 1.5$ 。

4) 与式 (13) 类似, 强攻加快速俯冲可构建为:

$$\begin{aligned} Y_2 &= X_{prey}^l - E | JX_{prey}^l - X_m^l | \\ Z_2 &= Y_2 + S \times LF(D) \\ X^{l+1} &= \begin{cases} Y_2, F(Y_2) < F(X^l) \\ Z_2, F(Z_2) < F(X^l) \end{cases} \end{aligned} \quad (15)$$

2 所提故障识别方法

2.1 HHO 优化 SVM

SVM 的性能与其参数有显著的相关性; 惩罚因子 C 和核参数 g 。GS 和 PSO 是两种常用的 SVM 参数选择方法。但是, 由于 GS 中网格大小的限制以及 PSO 的参数设置和搜索能力, 搜索效率和解的质量不高。为解决此问题, 引入新式元启发式优化算法 HHO。HHO 是一种随机优化算法, 具有较少的参数设置和更好的搜索能力, 以期 HHO 在 SVM 的参数优化方面比常用算法有更好的表现。HHO 优化 SVM 的伪代码如算法 1 所示。

算法 1 HHO 优化 SVM

输入: 初始种群数 N , 最大迭代次数 l_{max} , D -维搜索空间, 特征向量 R , SVM 的适应度函数 (F)

输出: X_{prey} (最优 C , 最优 g)

```

1: 初始化种群  $X_i$  ( $i = 1, 2, \dots, N$ )
2: while  $l < l_{max}$  do
3:   计算初始适应度函数值
4:   for  $X_i$  do
5:      $E \leftarrow 2E_0(1 - \frac{l}{l_{max}})$ 
6:     if  $|E| \geq 1$  then
7:       根据式 (9) 更新鹰群位置
8:     end if
9:     if  $|E| < 1$  then
10:      if  $r \geq 0.5$  and  $|E| \geq 0.5$  then
11:        根据式 (11) 更新鹰群位置
12:      else if  $r \geq 0.5$  and  $|E| < 0.5$  then
13:        根据式 (12) 更新鹰群位置
14:      else if  $r < 0.5$  and  $|E| \geq 0.5$  then
15:        根据式 (13) 更新鹰群位置
16:        计算适应度函数值
17:      else if  $r < 0.5$  and  $|E| < 0.5$  then
18:        根据式 (15) 更新鹰群位置
19:        计算适应度函数值
20:      end if
21:    end if
22:  end for
23: end while
24: 返回:  $X_{prey}$ : 最优  $C$  和最优  $g$ 
    
```

2.2 基于 SDMFE 与 HHO-SVM 的变压器故障识别

为了有效识别变压器内部故障, 提出了一种融合 SDMFE、HHO 和 SVM 的故障识别方法, 其总体框架如图 2 所示, 其包含如下 4 个主要步骤。

步骤 1) 提取故障特征。利用 SDMFE 从变压器振动信号中提取多尺度非线性故障特征;

步骤 2) 构建故障样本集。从每种类型的样本中随机选取一部分特征样本作为训练样本, 其余的作为测试样本;

步骤 3) 同步优化策略。采用 HHO 算法优化 SVM 参数, 保存最高训练精度对应的参数值作为 SVM 的最优参数;

步骤 4) 故障识别。使用最优参数的 SVM 对测试集进行故障识别。

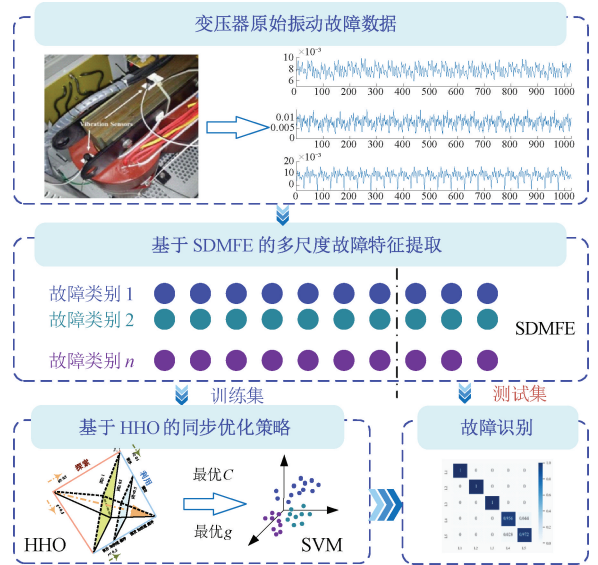


图 2 基于 SDMFE 和 HHO-SVM 的变压器故障识别框架

Fig. 2 Framework of transformer fault identification based on SDMFE and SVM with HHO

3 实例验证与分析

3.1 实验数据描述

为了验证所提出的故障诊断方法的有效性和可靠性, 采用文献 [16] 中变压器欠励磁、过励磁和匝间短路故障实测振动数据作为研究对象, 其中测试平台如图 3 所示。选取故障电流 5 A 和 10 A 表示不同程度的匝间短路故障。因此, 实验设置了 5 种变压器状态类别。以 1 024 的数据长度不重叠地分割变压器振动数据。每个状态类别包含 85 个样本, 全部实验数据由 425 个样本组成。随机选择 60 个样本作为训练集, 剩下的样本为测试集。表 1 描述了所使用样本的信息。5 种变压器振动信号的时域波形如图 4 所示。通过观测时域波形很难区分不同的变压器运行状态。事实上, 根据波形来做故障决策是不可靠的。

3.2 性能评估

为了充分验证所提方法的性能, 设置了 3 组对比实




图3 实验测试平台
Fig. 3 Test rig for experiment




图4 变压器不同状态下的振动信号
Fig. 4 Waveform of vibration signals of transformer under different conditions

1) 与不同信息熵对比

在特征提取阶段, SDMF E 与多尺度排列熵 (multiscale permutation entropy, MPE)^[17] 和多尺度散布熵 (multiscale dispersion entropy, MDE)^[18] 进行对比。SDMF E 的参数设置为: 嵌入维数 $m = 3$, 容限 $r = 0.2SD$ (SD 为信号的标准差), 尺度因子 $\tau = 10$ 。MDE 参数设置为: 嵌入维数 $m = 3$, 时延因子 $d = 1$, 类别参数 $c = 6$, 尺度因子 $\tau = 10$ 。MPE 的参数设置为: 嵌入维数 $m = 3$, 时延因子 $d = 1$, 尺度因子 $\tau = 10$ 。参照文献[19], SVM 参数的搜索范围为 $2^{-10} \sim 2^{10}$ 。

每类状态其中一个样本的 SDMF E、MPE 和 MDE 的值如表 2 所示。对比结果如表 3 所示, 表中展示了每一

类状态的识别准确率、整体的准确率和召回率。从中可知, 与 MPE 和 MDE 相比, 所提出的基于 SDMF E 的故障识别方法获得了最高识别准确率 (98.56%) 和召回率 (98.56%), 其中的 SVM 参数值如表 4 所示。这表明所提出的识别方法可以准确地识别变压器不同的故障类型。采用箱线图展示识别结果的数据分布, 如图 5 所示。可以看出, SDMF E 的中位数最大, 上下晶须小, 没有异常值, 而 MPE 和 MDE 的上下晶须较长, 存在一些异常值。这说明与 MPE 和 MDE 相比, SDMF E 识别稳定性高, 有效的识别结果多。因此, 基于 SDMF E 的特征提取方法能够有效地挖掘变压器内在丰富的故障信息, 提取的故障特征类间聚集度高, 类外分离度好。

表 1 实验所用样本信息

变压器状态	样本数	训练集	测试集	标签
欠励磁	85	60	25	L1
正常励磁	85	60	25	L2
过励磁	85	60	25	L3
匝间短路(5 A)	85	60	25	L4
匝间短路(10 A)	85	60	25	L5

表 2 各状态的一个样本在不同尺度因子下的 SDMF E、MPE 和 MDE

Table 2 SDMF E, MPE and MDE of one sample under different scale factors

标签	方法	尺度因子 τ									
		1	2	3	4	5	6	7	8	9	10
L1	SDMF E	1.093 5	0.400 3	0.578 8	0.583 0	0.574 0	0.555 4	0.631 0	0.466 5	0.485 2	0.414 5
	MPE	0.874 6	0.959 1	0.992 8	0.995 8	0.969 2	0.965 0	0.984 7	0.909 6	0.953 1	0.627 8
	MDE	0.825 1	0.840 4	0.844 4	0.760 1	0.692 6	0.745 3	0.725 4	0.687 7	0.674 6	0.611 4
L2	SDMF E	1.259 1	0.515 4	0.663 2	0.667 3	0.492 3	0.604 6	0.581 9	0.589 5	0.544 7	0.447 8
	MPE	0.952 0	0.988 0	0.989 4	0.979 1	0.917 2	0.974 7	0.979 7	0.982 2	0.964 5	0.932 4
	MDE	0.843 6	0.827 9	0.805 2	0.724 0	0.666 8	0.690 4	0.675 0	0.614 0	0.661 9	0.568 3
L3	SDMF E	1.040 4	0.411 0	0.587 3	0.581 6	0.662 1	0.661 9	0.721 4	0.584 5	0.533 7	0.390 7
	MPE	0.910 4	0.980 9	0.996 5	0.987 8	0.956 9	0.986 2	0.968 5	0.946 7	0.935 4	0.889 2
	MDE	0.789 7	0.813 8	0.777 8	0.719 3	0.649 7	0.663 5	0.664 1	0.631 7	0.621 4	0.541 8
L4	SDMF E	1.340 8	0.455 6	0.463 8	0.533 6	0.433 5	0.445 3	0.493 1	0.402 7	0.432 0	0.430 0
	MPE	0.983 8	0.967 4	0.985 3	0.990 5	0.997 7	0.997 3	0.977 1	0.994 1	0.983 8	0.999 1
	MDE	0.864 8	0.861 1	0.855 7	0.837 3	0.800 3	0.775 5	0.758 8	0.717 3	0.720 1	0.697 1
L5	SDMF E	1.433 1	0.451 8	0.555 0	0.453 0	0.492 6	0.508 2	0.466 3	0.412 3	0.422 8	0.4156
	MPE	0.946 4	0.981 7	0.992 1	0.968 1	0.992 3	0.983 2	0.988 7	0.982 9	0.987 8	0.998 8
	MDE	0.979 5	0.885 4	0.865 3	0.785 0	0.764 8	0.726 9	0.673 7	0.676 6	0.668 1	0.648 7

表 3 不同信息熵对比

Table 3 Comparison of different information entropies

标签	方法		
	MPE-HHO-SVM	MDE-HHO-SVM	SDMFE-HHO-SVM
L1	100%	100%	100%
L2	100%	100%	100%
L3	100%	99.6%	100%
L4	93.60%	90%	95.6%
L5	97.2%	92.4%	97.2%
准确率	98.16%	96.4%	98.56%
召回率	98.16%	96.4%	98.56%

表 4 SDMFE-HHO-SVM 模型中的最优 C 和 g

Table 4 Best C and g in SDMFE-HHO-SVM

实验次数	最佳 C	最佳 g
1	326.729 337 567 511	0.705 424 5127 837 84
2	95.925 724 277 621 9	1.997 398 856 818 15
3	929.640 681 421 519	16.093 319 302 782 7
4	410.525 129 240 028	12.042 799 113 172 7
5	10.485 504 309 528 7	5.093 459 849 959 31
6	520.034 381 853 370	24.551 701 963 638 4
7	9.814 186 617 167 63	6.567 565 581 386 23
8	7.256 998 963 286 52	4.587 044 457 937 06
9	69.967 226 435 899 0	1.861 261 772 013 34
10	18.746 135 019 730 3	4.817 375 702 466 67




图 5 不同信息熵的箱型图

Fig. 5 Boxplots of different information entropies

2) 与不同优化策略对比

在参数同步优化阶段,为了验证所采用的基于 HHO 的优化策略的优势,将其与网格搜索(GS)和粒子群优化算法(PSO)进行对比。GS 和 PSO 的参数设置参考了文献[13]和[19]的设置方式。

对比结果如表 5 所示。由表可知,基于 GS 的搜索策略识别准确率和召回率最低,说明 GS 面对新的数据分布难以选择合适的网格大小和步长参数,获得的结果较为保守。PSO 的识别效果比 GS 要好,说明 PSO 在面对不同分布的数据无需选择特定的参数,有着比 GS 更好的适应性。而基于 HHO 的优化策略准确率和召回率最高,说明相较于 GS 和 PSO,HHO 能够凭借自身独特的搜索结构在新的数据空间中获得更好的 SVM 参数值。从图 6

的箱线图可以看出,基于 HHO 的识别结果中位数最高,箱型大小与 PSO 相当,没有异常值。GS 的箱子长度最小,中位数最低,且存在大量的异常值。这表明 HHO 在具有较高的识别精度下能保持与 PSO 相当识别稳定性。因此,HHO 相对于 GS 和 PSO 更适用于 SVM 的参数选择。

表 5 不同优化策略对比

Table 5 Comparison of different optimization schemes

标签	方法		
	GS-SVM	PSO-SVM	HHO-SVM
L1	99.82%	100%	100%
L2	100%	100%	100%
L3	100%	100%	100%
L4	91.09%	96%	95.6%
L5	90.36%	92.4%	97.2%
准确率	96.25%	97.68%	98.56%
召回率	96.25%	97.68%	98.56%




图 6 不同优化策略的箱型图

Fig. 6 Boxplots of different optimization schemes

3) 与不同分类器对比

为了验证 HHO-SVM 的变压器故障识别能力,所提方法与两种分类器反向传播神经网络(back propagation neural network, BPNN)^[20]和支持向量数据描述(support vector data description, SVDD)^[21]进行对比。对比结果如表 6 所示。

表 6 不同分类器对比

Table 6 Comparison of different classifiers

标签	方法		
	SDMFE-BPNN	SDMFE-SVDD	SDMFE-HHO-SVM
L1	98.8%	100%	100%
L2	98.8%	100%	100%
L3	99.6%	100%	100%
L4	66.8%	93.82%	95.6%
L5	80%	64.75%	97.2%
准确率	89.44%	92.25%	98.56%
召回率	88.8%	92.25%	98.56%

由表 6 可知,BPNN 的识别准确率和召回率最低,说明 BPNN 面对高维、小样本的变压器故障数据时拟合性

能较差。而 HHO-SVM 具有最高的识别准确率和召回率,表明 SVM 在 HHO 的优化下能够有效处理变压器故障数据。图 7 箱线图显示 BPNN 的箱型长,中位数小,这表明 BPNN 识别精度和稳定性都较差。SVDD 识别稳定性与 HHO-SVM 相当,但其中位数相对较小,识别准确度低于 HHO-SVM,且有一定的异常值。因此,相较于 BPNN 和 SVDD,在解决小样本问题上,HHO-SVM 具有更好的性能。




图 7 不同分类器的箱型图

Fig. 7 Boxplots of different classifiers

4) 可视化评估

综合上述对比分析,所提 SDMFE-HHO-SVM 方法的变压器故障识别性能得到充分的验证。图 8 为所提方法的多类混淆矩阵,完整地记录了变压器不同故障状态的识别结果,包括分类信息和错误分类信息。多类混淆矩阵主对角线上的元素代表了变压器各状态的识别准确率。从图 8 可以看出,所提方法能准确识别出不同励磁条件下变压器状态,也能有效识别不同匝间短路故障,而识别匝间短路(5A)的准确率最低。

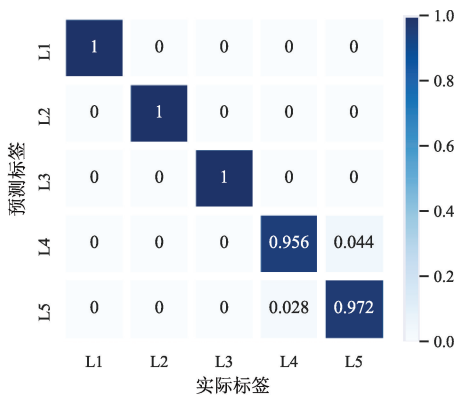


图 8 所提方法的多类混淆矩阵

Fig. 8 Confusion matrix of the proposed method

4 结 论

本文以变压器的振动信号分析为基础,提出了融合 SDMFE、HHO 和 SVM 的故障识别方法,有效地提取多种故障特征,能够准确地识别变压器内部过励磁、欠励磁和匝间短路等故障。主要研究结论如下:

1) 与 MPE 和 MDE 相比,SDMFE 可以从复杂的振动信号中提取丰富的多尺度非线性故障特征,从多个时间尺度下全面刻画故障特性,具有良好的故障分离效果,有助于提高分类器的识别性能。

2) 与基于网格搜索和 PSO 的优化策略相比,基于 HHO 的优化策略优化 SVM 的稳定性和效果更好,具有较好的数据适应能力。

3) SDMFE 结合 HHO-SVM 的变压器故障识别方法与其他相应的方法对比中获得更好的识别性能。

参考文献

[1] 张朝龙,何怡刚,杜博伦,等. 基于深度学习的电力变压器智能故障诊断方法[J]. 电子测量与仪器学报, 2020, 34(01): 81-89.
ZHANG CH L, HE Y G, DU B L, et al. Intelligent fault diagnosis method of power transformer using deep learning [J]. Journal of Electronic Measurement and Instrumentation, 2020,34(1):81-89.

[2] 陈民铀,王明林,郑杰,等. 计及不对称负荷的配电变压器短路电抗在线检测方法[J]. 高电压技术, 2015, 41(3):881-886.
CHEN M Y, WANG M L, ZHENG J, et al. On-line Detection of short-circuit reactance of distribution transformers considering the condition of asymmetric load [J]. High Voltage Engineering, 2015,41(3):881-886.

[3] DUAN J, HE Y, WU X. Serial transfer learning (STL) theory for processing data insufficiency: Fault diagnosis of transformer windings [J]. International Journal of Electrical Power & Energy Systems, 2021, 130: 106965.

[4] 殷作洋,吴肖锋,仲伟坤. 基于随机森林的变压器故障识别与实例分析[J]. 电子测量技术, 2020, 43(23): 63-67.
YIN Z Y, WU X F, ZHONG W K. Transformer fault recognition based on random forest and case analysis [J]. Electronic Measurement Technology, 2020, 43(23): 63-67.

[5] 赵莉华,徐立,刘艳,等. 基于点对称变换与图像匹配的变压器机械故障诊断方法[J]. 电工技术学报, 2021, 36(17): 3614-3626.
ZHAO L H, XU L, LIU Y, et al. Transformer mechanical fault diagnosis method based on symmetrized dot patter and image matching [J]. Transactions of China Electrotechnical Society, 2021, 36(17): 3614-3626.

[6] 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 CH, CHEN X, CAI G W, 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.
- [7] LIU X, HE Y, WANG L. Adaptive transfer learning based on a two-stream densely connected residual shrinkage network for transformer fault diagnosis over vibration signals[J]. Electronics, 2021, 10(17): 2130.
- [8] ZHANG C, HE Y, JIANG S, et al. Transformer fault diagnosis method based on self-powered RFID sensor tag, DBN, and MKSVM[J]. IEEE Sensors Journal, 2019, 19(18): 8202-8214.
- [9] BEHJAT V, MAHVI M. Statistical approach for interpretation of power transformers frequency response analysis results [J]. IET Science Measurement & Technology, 2015, 9(3): 367-375.
- [10] HE S, LIU Y, CHEN J, et al. Wavelet transform based on inner product for fault diagnosis of rotating machinery[J]. Mechanical Systems & Signal Processing, 2016, 70: 1-35.
- [11] AZAMI H, FERNÁNDEZ A, ESCUDERO J. Refined multiscale fuzzy entropy based on standard deviation for biomedical signal analysis [J]. Medical & Biological Engineering & Computing, 2017, 55(11): 2037-2052.
- [12] SHAO K, FU W, TAN J, et al. Coordinated approach fusing time-shift multiscale dispersion entropy and vibrational Harris hawks optimization-based SVM for fault diagnosis of rolling bearing [J]. Measurement, 2021, 173: 108580.
- [13] FARIS H, HASSONAH M A, AL-ZOUBI A M, et al. A multi-verse optimizer approach for feature selection and optimizing SVM parameters based on a robust system architecture [J]. Neural Computing and Applications, 2017, 30(8): 2355-2369.
- [14] 陶志勇, 于子佳, 林森. PSO_SVM 算法在太阳能电池板裂缝缺陷检测研究 [J]. 电子测量与仪器学报, 2021, 35(1): 18-25.
TAO ZH Y, YU Z J, LIN S, et al. Research on crack defect detection of solar cell based on PSO_SVM [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(1): 18-25.
- [15] HEIDARI A A, MIRJALILI S, FARIS H, et al. Harris hawks optimization: Algorithm and applications [J]. Future Generation Computer Systems, 2019, 97: 849-872.
- [16] ZOLLANVARI A, KUNANBAYEV K, AKHAVAN BITAGHSIR S, et al. Transformer fault prognosis using deep recurrent neural network over vibration signals [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-11.
- [17] LI Y, XU M, WEI Y, et al. A new rolling bearing fault diagnosis method based on multiscale permutation entropy and improved support vector machine based binary tree [J]. Measurement, 2016, 77: 80-94.
- [18] ROSTAGHI M, ASHORY M R, AZAMI H. Application of dispersion entropy to status characterization of rotary machines [J]. Journal of Sound and Vibration, 2019, 438: 291-308.
- [19] FU W, TAN J, ZHANG X, et al. Blind parameter identification of MAR model and mutation hybrid GWO-SCA optimized SVM for fault diagnosis of rotating machinery [J]. Complexity, 2019, 2019(51): 1-17.
- [20] RAM J C H, SIMON S P, SUNDARESWARAN K, et al. Auxiliary hybrid PSO-BPNN based transmission system loss estimation in generation scheduling [J]. IEEE Transactions on Industrial Informatics, 2017, 13(4): 1692-1703.
- [21] 付文龙, 谭佳文, 王凯. 基于 VMD 散布熵与改进灰狼优化 SVDD 的轴承半监督故障诊断研究 [J]. 振动与冲击, 2019, 38(22): 190-197.
FU W L, TAN J W, WANG K. Semi-supervised fault diagnosis of bearings based on the VMD dispersion entropy and improved SVDD with modified grey wolf optimizer [J]. Journal of Vibration and Shock, 2019, 38(22): 190-197.

作者简介



邵凯旋, 现为武汉大学博士研究生, 主要研究方向为能源装备状态监测、信息处理与故障诊断。

E-mail: skaixuan@whu.edu.cn

Shao Kaixuan is currently a Ph. D. candidate at Wuhan University. His main research interests include energy equipment condition monitoring, information processing and fault diagnosis.



何凯刚 (通信作者), 1992 年于湖南大学获得硕士学位, 1996 年于西安交通大学获得博士学位, 现为武汉大学教授, 主要研究方向为能源装备状态监测、信息处理与故障诊断, 研究方向涉及电力电子电路理论及其应用、模拟和混合信号电路的测试和故障诊断、智能电网和卫星通信的监测和智能信号处理。

E-mail: yghe1221@whu.edu.cn

He Yigang (Corresponding author) received his M. Sc. degree from Hunan University in 1992 and Ph. D. degree from Xi'an Jiao Tong University in 1996. Now he is a professor in Wuhan University. His main research interests include power electronic circuit theory and its applications, testing and fault diagnosis of analog and mixed-signal circuits, electrical signal detection, smart grid, satellite communication monitoring, and intelligent signal processing.