

DOI: 10.19595/j.cnki.1000-6753.tces.240903

基于改进蜣螂优化算法深度混合核极限学习机的高压断路器故障诊断

范兴明 许洪华 张思舜 李涛 蒋延军 张鑫

(桂林电子科技大学电气工程及其自动化系 桂林 541004)

摘要 针对高压断路器机械故障诊断准确率偏低的问题, 该文提出一种基于改进蜣螂优化算法 (IDBO) 优化深度混合核极限学习机 (DHKELM) 的故障诊断方法。首先, 采用逐次变分模态分解 (SVMD) 对高压断路器合闸振动信号进行分解, 得到若干个含本征频率的固有模态分量 (IMF); 其次, 提取各 IMF 分量的功率谱熵构建特征向量矩阵, 并利用 t 分布-随机邻域嵌入算法 (t -SNE) 对特征向量进行数据降维; 然后, 引入融合 Tent 混沌映射、黄金正弦策略、自适应 t 分布扰动策略对传统蜣螂优化算法 (DBO) 进行改进, 并使用 IDBO 对 DHKELM 进行参数优化, 完成 IDBO-DHKELM 高压断路器故障诊断模型的构建; 最后, 通过搭建模拟故障的实物断路器实验平台进行验证, 结果表明, 该文提出的方法在故障诊断上的准确率达到 98.33%, 相较于其他故障诊断模型在多项分类评价指标上均有显著提升, 为准确、可靠地诊断高压断路器机械故障提供了新方案。

关键词: 高压断路器 改进蜣螂优化算法 深度混合核极限学习机 故障诊断 逐次变分模态分解

中图分类号: TM561

0 引言

高压断路器作为电力系统中关键的控制和保护装置, 其发生故障可能会导致重大的安全事故和经济损失^[1]。鉴于此, 开发出针对性的方法来识别和处理高压断路器潜在的机械故障, 已成为电力行业迫切需要解决的难题^[2]。

随着人工智能技术的快速发展, 支持向量机 (Support Vector Machine, SVM)、卷积神经网络 (Convolutional Neural Networks, CNN) 及极限学习机 (Extreme Learning Machine, ELM) 等机器学习算法被广泛应用于高压断路器的故障诊断中。其中, ELM 相较于其他方法具有训练速度快、参数调整需求少及泛化性能良好等优势。文献[3]利用 ELM 对高压断路器进行故障诊断, 尽管这种方法诊断效果

较好, 然而 ELM 也存在隐含层节点数随机和模型稳定性较差的缺陷。文献[4]引入核函数至 ELM 中, 构建混合核极限学习机 (Hybrid Kernel Extreme Learning Machine, HKELM), 以进一步增强模型的非线性学习能力。文献[5]为了增强 HKELM 模型的学习能力和泛化性, 将深度学习与 HKELM 结合, 构建深度混合核极限学习机 (Deep Hybrid Kernel Extreme Learning Machine, DHKELM) 模型。其结合了 ELM 的高效学习速率和深度学习的层次结构, 通过使用反向传播算法训练深层网络, 提高了模型的训练速度和处理复杂数据的能力。

由于 DHKELM 模型的超参数较多, 故障诊断准确率易受人工调整参数的影响, 因此可利用元启发智能算法优化其参数以提高整体分类性能。其中, 常用的智能优化算法有粒子群优化 (Particle Swarm Optimization, PSO) 算法、麻雀优化算法、鲸鱼优化算法 (Whale Optimization Algorithm, WOA) 等。蜣螂优化算法 (Dung Beetle Optimizer algorithm, DBO) 是由东华大学沈波教授团队基于群体搜索提出的智能

优化算法^[6]，其主要寻优框架为模仿蜚螂的生物行为过程，具备较强的搜索能力和较高的收敛效率。然而，DBO 也存在智能优化算法中常见的局限性，包括全局搜索能力不足和容易陷入局部最优解。

综上所述，本文提出了一种基于融合多策略改进蜚螂优化算法 (Improved Dung Beetle Optimizer algorithm, IDBO) 优化 DHKELM 参数的高压断路器故障诊断方法。首先，采用逐次变分模态分解 (Successive Variational Mode Decomposition, SVM) 对高压断路器合闸振动信号进行多尺度分解；其次，计算各固有模态分量 (Intrinsic Mode Function, IMF) 的功率谱熵 (Power Spectral Entropy, PSE) 构建特征向量矩阵，并利用 t -分布随机邻域嵌入 (t -distributed Stochastic Neighbor Embedding, t -SNE) 算法进行数据降维；然后，引入 Tent 混沌映射、黄金正弦策略和自适应 t 分布策略对 DBO 算法进行改进，并将其用于优化 DHKELM 模型的超参数；最后，通过将 IDBO-DHKELM 模型与多个传统故障诊断模型进行对比，验证了本文所提出方法的有效性。

1 深度混合核极限学习机理论基础

混合核极限学习机 (HKELM) 是一种集成了极限学习机 (ELM) 的快速学习能力和混合核函数的高维映射能力的机器学习算法^[7]。然而，HKELM 在故障诊断任务中仍存在一定的缺陷，如在处理多维数据时，由于高维映射可能会导致数据过拟合，容易受到数据中异常值的影响，进而降低在分类任务中的稳定性^[8]。

为提高 HKELM 模型在高压断路器故障诊断任务中的准确率，将深度学习中自动编码器 (Auto Encoders, AE) 思想引入 HKELM 模型中，增强模型的数据压缩表示和特征提取的能力，进而提升其分类性能^[9]。

DHKELM 算法框架如图 1 所示。将 AE 思想融




图 1 DHKELM 算法框架

Fig.1 Framework of the DHKELM algorithm

合于 HKELM 中，构建 DHKELM 模型的具体步骤如下：

(1) 在 n 层 ELM-AE 中随机生成输入层和隐含层间的正交参数 W_n 和 b_n 。

(2) 将第 t 个隐含层的输出矩阵 H_t 作为下一层 ELM-AE 的输入，依次计算出所有 ELM-AE 的隐含层输出 H_t 和权重 β_{n+1} ，其更新表达式为

$$H_t = g(W_t X + b_t) \quad (1)$$

$$\beta_{n+1} = \left(\frac{E}{C} + H_t^T H_t \right)^{-1} H_t^T H_n \quad (2)$$

式中， $g(x)$ 为激活函数； W_t 为第 t 层的权重矩阵； X 为输入的数据矩阵； E 为单位矩阵； C 为正则化参数，用于控制模型的复杂度。

(3) 进一步地，通过将 ELM-AE 隐含层堆叠起来，前一层的输出 H_n 作为当前层的输入 H_{n+1} ，构建出多层级分类结构，有

$$\begin{cases} H_0 = X_0 \\ H_{n+1} = g(\beta_{n+1}^T H_n) \end{cases} \quad n=1, 2, 3, \dots, m-1 \quad (3)$$

式中， H_0 为初始隐含层状态； X_0 为初始输入。

完全连接层的输出 R 表达式为

$$R = g(\omega_{in} H_{n+m} + \theta_{in}) \quad (4)$$

式中， ω_{in} 和 θ_{in} 分别为全连接层的输入权值和偏差。

(4) 在神经网络模型的参数调优阶段，通过调整全连接层，确定最终隐含层 H 与编码器输出 Y 之间的权重和偏置参数。随后，将解码器组件构建为一个传统的全连接神经网络架构。最终，可得到重建的数据，输出 Y_d 的表达式为

$$Y_d = g(\omega_{out} Y + \theta_{out}) = g(\omega_{out} g(\omega_{in} H_m + \theta_{in}) + \theta_{out}) \quad (5)$$

式中， ω_{out} 和 θ_{out} 分别为全连接层输出的权值和偏差； H_m 为第 m 层隐含层的输出矩阵。

DHKELM 模型目标函数的输入误差 e 可表示为

$$e = \arg \min_{\omega_{in}, \theta_{in}, \omega_{out}, \theta_{out}} \|Y_d - I_d\|_2^2 \quad (6)$$

式中， Y_d 为目标输出； I_d 为实际输出。

与传统 ELM 相比，DHKELM 采用多隐含层结构，结合深度学习中 AE 提取数据特征的能力和 ELM 快速训练的优势，从而整体提升 DHKELM 模型的性能^[10]。

2 蜣螂优化算法及其改进

鉴于深度混合核极限学习机 (DHKELM) 算法的超参数较多、人工预先设定模型参数难以达到高压断路器故障诊断的最优效果, 本文引入改进蜣螂优化算法 (IDBO) 对 DHKELM 的隐含层节点数、惩罚系数、正则化系数 C 、 K_{RBF} 和 K_{poly} 的核参数 σ 、 q 、 p 和各自权重进行优化, 以提高模型在高压断路器故障诊断任务中的泛化能力和准确率。

2.1 标准蜣螂优化算法

DBO 是一种基于元启发式思想的智能优化算法。其灵感来源于蜣螂在自然界中的一系列行为, 包括滚球、跳舞、觅食、偷窃和繁殖^[11]。DBO 在迭代更新过程中, 蜣螂的种群由四种不同类型蜣螂代理构成, 即滚球蜣螂、繁育蜣螂、小蜣螂和偷窃蜣螂, 分别对应迭代中的搜索过程、信息传递、跳出局部最优解和引入新策略。

尽管 DBO 在优化性能和收敛效率方面具有显著优势, 但在全局搜索以及规避局部最优陷阱方面仍存在一定缺陷。针对以上局限性, 本文将 Tent 混沌映射、黄金正弦策略和自适应 t 分布扰动融入 DBO 中, 旨在进一步增强 DBO 算法的综合性能。

2.2 改进蜣螂优化算法

融合多策略对标准蜣螂优化算法进行改进, 具体流程如图 2 所示。

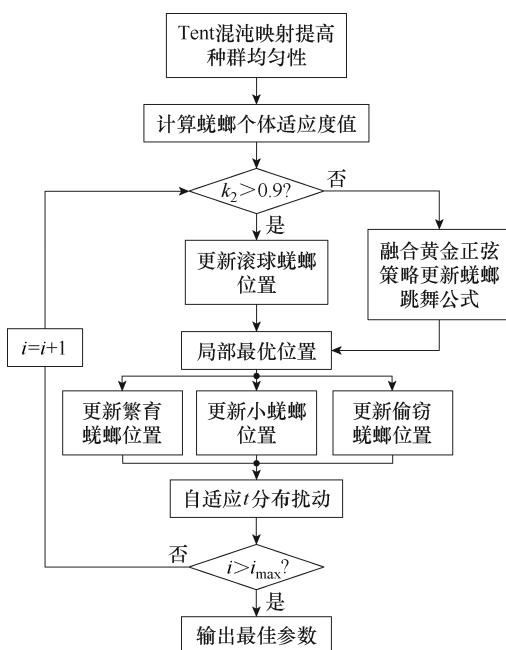


图 2 融合多策略改进蜣螂优化算法流程

Fig.2 Flow chart of the improved dung beetle optimization algorithm incorporating multiple strategies

在 DBO 算法的框架内, 假设蜣螂种群由 K 个个体组成, 每个个体 k 对应一个候选解。第 k 个个体在第 i 次迭代中的位置向量 $\mathbf{x}_i(k)$ 具体表达式^[12]为

$$\mathbf{x}_i(k) = [\mathbf{x}_1(k) \ \mathbf{x}_2(k) \ \cdots \ \mathbf{x}_{iS}(k)] \quad (7)$$

式中, S 为搜索空间的维度。

1) Tent 混沌映射^[13]

智能优化算法的初始种群多样性对算法的收敛速度和精度具有重要影响。混沌映射具备随机性和遍历性等特征, 能够加快收敛速度并在一定程度上避免算法陷入局部最优解。本文通过引入 Tent 混沌映射, 优化 DBO 的初始化过程, 增强种群中个体的随机性, 从而提高算法的收敛速度和精度, 其数学表达式为

$$X_{n+1} = \begin{cases} \frac{X_n}{l} & 0 \leq X_n < l \\ \frac{1-X_n}{1-l} & l \leq X_n < 1 \end{cases} \quad (8)$$

式中, l 为 $[0, 1]$ 的常数。

2) 黄金正弦策略^[14]

黄金正弦策略是一种基于正弦函数的迭代寻优方法, 常用于在二维空间中搜索函数的极值点。引入黄金正弦策略改进滚球蜣螂的位置更新公式, 从而增强蜣螂优化算法的全局搜索能力, 其数学表达式为

$$\begin{cases} x_i(t+1) = x_i(t) |\sin e_1| - e_2 \sin e_1 |y_1 X^b - y_2 x_i(t)| \\ y_1 = a(1-g_1) + bg_1 \\ y_2 = ag_1 + b(1-g_1) \end{cases} \quad (9)$$

式中, X^b 为当前最优个体的位置; e_1 为 $[0, 2\pi]$ 的随机数, 决定蜣螂个体的移动距离; e_2 为 $[0, \pi]$ 的随机数, 决定蜣螂个体的位置更新方向; a 和 b 的初始值分别为 $-\pi$ 和 π ; g_1 为黄金分割数; y_1 、 y_2 为含黄金分割数的系数。

3) 自适应 t 分布扰动^[15]

针对 DBO 后期因种群多样性减少, 导致算法易陷入局部最优的问题, 采用自适应 t 分布策略对蜣螂个体位置进行扰动, 提高其跳出局部最优解的能力。蜣螂个体经自适应 t 分布扰动后的更新位置为

$$x_i(k+1) = x_i(k) + x_i(k) W_i(k) \quad (10)$$

式中, $x_i(k)$ 为改进后的第 k 只蜣螂个体位置; $W_i(k)$ 为随机扰动项。

2.3 IDBO 算法性能测试

为对比各项改进策略对 DBO 性能的影响和测


试 IDBO 的改进效果, 选用 CEC2005 测试集中的 f_1 单模态和 f_2 多模态函数进行性能测试^[16], 并与传统的粒子群优化 (PSO) 算法、鲸鱼优化算法 (WOA)、DBO 进行比较。其中, f_1 与 f_2 测试函数的表达式为

$$f_1(x) = \sum_{i=1}^n x_i^2 \quad (11)$$

$$f_2(x) = \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos \frac{x_i}{\sqrt{i}} + 1 \quad (12)$$

设置各优化算法的迭代次数为 100 次, 种群大小为 50, f_1 和 f_2 函数中自变量的取值范围分别为 $[-100, 100]$ 和 $[-600, 600]$ 。由于 f_2 函数已经内嵌了 f_1 函数, 并且多模态测试函数更能体现寻优的性能, 因此本文只对 f_2 函数进行了各项改进策略的测试, 统计各项改进策略对 f_2 函数和各优化算法对 f_1 、 f_2 函数的寻优结果, 如图 3 所示。

由图 3a 可知, DBO 引入 Tent 混沌映射, 能在迭代次数较少的情况下更快收敛至最优解; 引入黄金正弦策略, 在整个迭代过程中表现出更平滑和持续的下降曲线, 最终达到更低的适应度值; 而引入自适应 t 分布扰动, 在迭代结束时能获得更接近全局最优的解。由图 3b、图 3c 可知, 四种寻优算法在两个测试函数寻优过程中, IDBO 分别第 5 次和第 10 次迭代时, 均已经达到最优适应度, 相较于 PSO、WOA 和 DBO, 本文提出的 IDBO 在寻找最



(c) 各优化算法寻优 f_2 函数

图 3 测试函数寻优结果

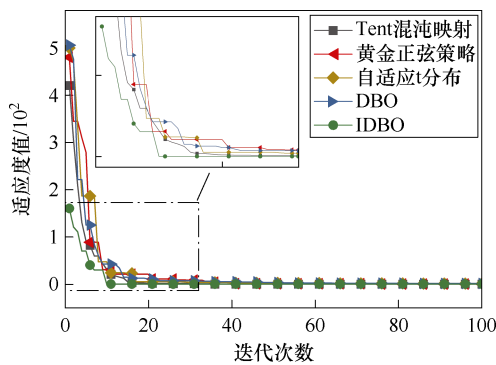
Fig.3 Test function optimization result graph

优解过程中具有更高的寻优精度、更快的收敛速度。


总的来说, 通过引入 Tent 混沌映射、黄金正弦策略和自适应 t 分布扰动三种策略改进 DBO, 分别提升了算法的收敛速度、寻优精度和全局搜索能力。经多策略融合改进的 IDBO, 在寻优分类算法参数最优解的精度和收敛速度上表现更优, 这有助于提升后续故障诊断的准确率。

3 高压断路器故障诊断流程框架

本文采用 SVM 对振动信号进行分解, 提取各固有模态分量 (IMF) 的功率谱熵构造特征向量, 并使用 t -SNE 对多维特征向量进行数据降维, 引入融合多策略改进的 IDBO 对 DHKELM 算法进行参数优化, 最后对降维后的特征向量进行故障诊断。高压断路器故障诊断流程如图 4 所示。



(a) 各改进策略寻优 f_2 函数



(b) 各优化算法寻优 f_1 函数

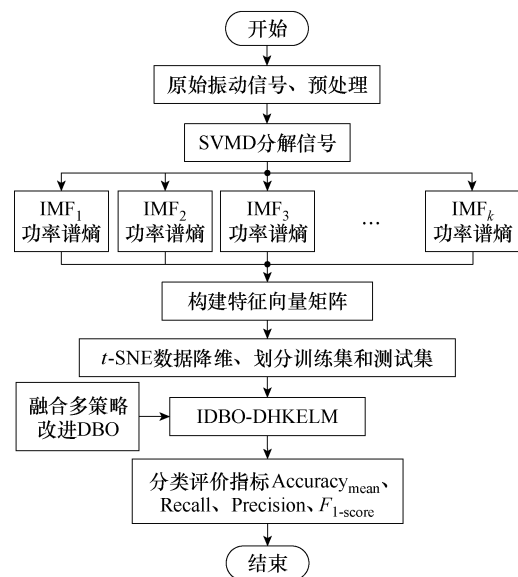


图 4 高压断路器故障诊断流程

Fig.4 Flowchart of high-voltage circuit breaker fault diagnosis

具体步骤为:

(1) 采集高压断路器在正常状态和缓冲弹簧疲劳、基座松动、绝缘子松动、传动轴卡涩四种故障状态下的合闸振动信号, 并进行滤波预处理。

(2) 使用 SVM 对预处理后的信号进行分解, 并对各 IMF 分量提取功率谱熵, 构建特征向量。

(3) 采用 t -SNE 对特征向量进行数据降维, 且按一定比例划分训练集和测试集。

(4) 使用经多策略改进后的 DBO 寻优 DHKELM 算法的关键参数。

(5) 将优化后的 DHKELM 对特征向量进行故障诊断, 输出最终分类评价指标平均准确率、精确率、召回率和 F_1 分数。

4 实验验证

4.1 数据采集

为验证上述所提方法的有效性, 本文以一台 TY-1S-12/630-16 型单相真空高压断路器作为研究对象, 具体的样机及软硬件平台装置如图 5 所示。



图 5 实验平台

Fig.5 Experimental platform

在信号采集方面, 本文采用激光测振仪作为采集振动信号的传感器。该激光测振仪的最大速度量程为 10 m/s, 频率范围为 DC~2.5 MHz, 适用于采集非平稳、强时变的振动信号。首先, 通过分合闸控制器控制高压断路器的合闸, 同时激光测振仪实时采集样机的振动信号。随后, 经路由器将所采集信号的数字量传输至上位机, 构成完整的高压断路器振动信号采集平台。

以高压断路器合闸过程为例, 工作状态设置见表 1, 人为模拟设置了四种典型机械故障。为保证振动信号的充分采集, 设置信号采集时间为 1 000 ms, 采样频率为 78 125 Hz。分别采集高压断路器在正常状态、缓冲弹簧疲劳、基座松动、绝缘子松动、传动轴卡涩五种状态下的合闸振动信号, 每种工况各 60 个样本, 共计 300 个样本。

表 1 工作状态设置

Tab.1 Operational state settings

类别标注	工况名称	模拟方式	样本数
1	正常状态	—	60
2	缓冲弹簧疲劳	调节缓冲弹簧张紧力	60
3	基座松动	松动 4 个基座螺栓	60
4	绝缘子松动	松动绝缘子固定螺栓	60
5	传动轴卡涩	在传动轴增加卡涩异物	60

采集得到的高压断路器五种状态合闸时域振动信号如图 6 所示。




图 6 高压断路器五种工况合闸时域振动信号

Fig.6 Time-domain diagram of closing vibration signals for five operating conditions of high-voltage circuit breaker

由图 6 可以看出,当高压断路器发生缓冲弹簧疲劳故障时,振动幅度逐渐减小,表明弹簧的弹性减弱;当发生基座松动故障时,振幅略有减小,但振动持续时间延长,反映出基座松动引起的机械不稳定性;当绝缘子出现松动故障时,振动幅度整体显著减弱,这是因为绝缘子松动削弱了振动的传递效果;当发生传动轴卡涩故障时,振动响应时间缩短,这表明传动轴的卡涩导致间歇性的机械卡滞现象。

尽管不同工况振动信号在时域上的幅值和波形存在差异,但这些特征不足以精确区分高压断路器的工作状态。因此,需要进一步分析信号的频域信息,以提取更具辨识力的故障特征。

4.2 特征提取

当使用变分模态分解(VMD)处理信号时,如果 IMF 分量的个数 k 和二次项惩罚因子 α 设置不恰当,可能会导致模态混叠或者过分解。而连续变分模态分解(SVMD)对信号采取顺序分解策略,直至提取所有的 IMF 分量,或重构误差小于阈值时结束,且不需要提前设置分解的模态数量,极大地降低了计算复杂度^[17]。针对高压断路器合闸振动信号中频域所含故障信息较为丰富的特性,采用 SVMD 对信号进行自适应分解,以正常合闸振动信号为例,设置 SVMD 的惩罚系数 $\beta=2\ 000$,收敛容差阈值 $T_{01}=1\times 10^{-6}$,经分解后得到 7 个中心频率不同的 IMF 分量。

功率谱熵(PSE)是一种衡量信号频谱复杂性的指标,反映了频谱分布的均匀性^[18]。提取各 IMF 分量的功率谱熵作为特征值,可以有效表征高压断路器的不同工作状态。功率谱熵的计算公式为

$$P_{se} = -\sum_{n=1}^N p_n \lg p_n \quad (13)$$

式中, p_n 为第 n 个功率谱所占整体的百分比; N 为信号长度。

4.3 数据降维

t -SNE 是一种基于 SNE 的非线性降维算法,可以将高维数据映射至 2 维或 3 维空间中并可可视化。本文对 4.1 节中实验采集的 300 组高压断路器合闸振动信号进行 SVMD 分解后,提取各 IMF 分量的功率谱熵,构建成 300×7 维的特征向量。此时,由于特征向量维度过高,数据量较大,特征表达不明确,不利于后续状态分类,因此采用 t -SNE 对特征向量进行数据降维,将原始的高维特征向量映射至 3 维空间中,降维结果的空间分布情况如图 7 所示。

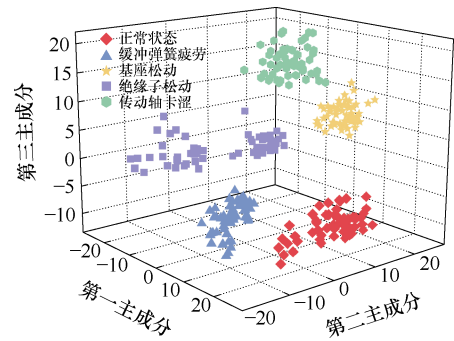


图 7 t -SNE 降维后的数据分布

Fig.7 Data distribution after t -SNE dimensionality reduction

由图 7 可知,经 t -SNE 降维后,同一状态的样本表现出了明确的聚类特征,而不同状态的样本在 t -SNE 的映射结果中被分开,形成了不同紧密的簇,有助于提高后续故障诊断的准确率。

5 故障诊断结果

在 4.3 节中,经 t -SNE 降维后,得到 300×3 维的功率谱熵特征向量,并按 6:4 的比例随机划分为训练集和测试集,以便后续进行分类模型的训练和测试。

5.1 各模型故障诊断评价指标对比

为验证本文所提出的 IDBO-DHKELM 模型在高压断路器故障诊断中的有效性和优越性。采用相同的数据集,对比 DHKELM 和 SVM、ELM、CNN 模型的性能;此外,为验证经多策略融合改进后的 IDBO 优化效果,对比了 PSO-DHKELM 模型和 DBO-DHKELM 模型的性能,不同优化算法的参数设置与 2.3 节保持一致。并采用分类指标:平均准确率(Accuracy_{mean})、精确率(Precision)、召回率(Recall)和 F_1 分数(F_1 -score)对各模型进行多方面评估^[19]。其中,平均准确率是评估模型的整体预测结果;精确率表示正确预测数量在预测结果中的占比;召回率表示正确预测数量在实际结果中的占比; F_1 分数则用于衡量模型预测的准确性和完整性, F_1 分数的数学模型为

$$F_1\text{-score} = 2 \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (14)$$

最终得到不同模型分类结果如图 8 所示,并统计各模型分类评价指标见表 2。

由图 8 和表 2 可知,在 120 个测试集样本中,本文提出的 IDBO-DHKELM 模型在故障诊断上仅出现两个样本的误判,平均准确率达到 98.33%。

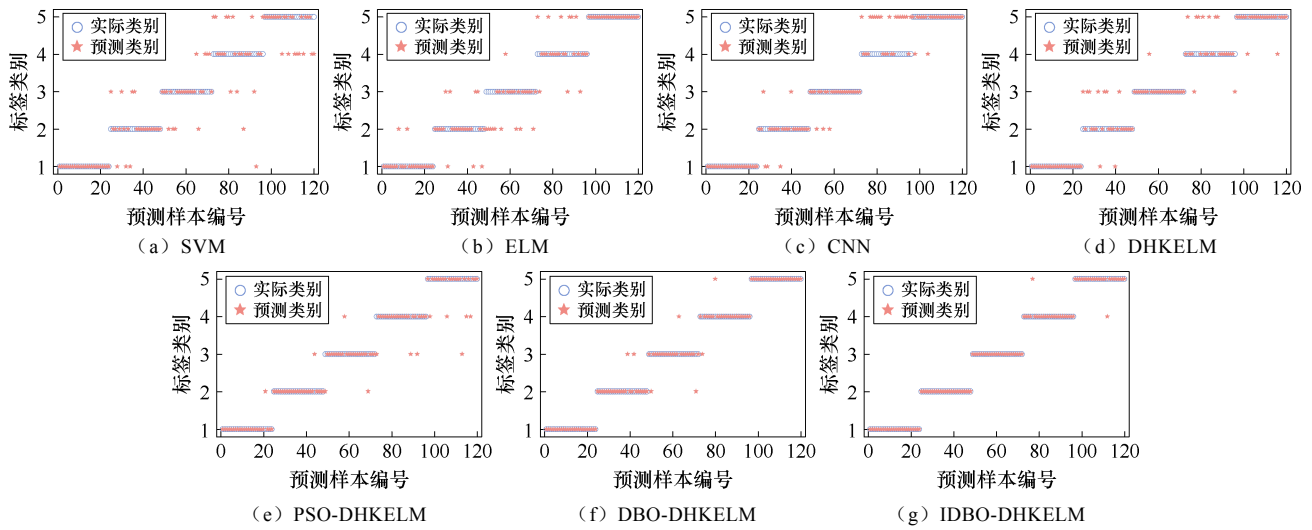


图8 不同模型故障诊断结果

Fig.8 Fault diagnosis results of different models

表2 不同模型分类指标对比

Tab.2 Comparison of classification metrics for different models

(续)

分类模型	评价指标	正常状态	缓冲弹簧疲劳	基座松动	绝缘子松动	传动轴卡涩
SVM	Precision	85.71	77.27	69.57	50	69.57
	Recall	100	70.83	66.67	50	66.67
	F_1 -score	92.3	73.9	68.09	50	68.09
	Accuracy _{mean}	70.83				
	Accuracy _{mean}	70.83				
ELM	Precision	88	60.71	66.67	93.75	80
	Recall	91.67	70.83	58.33	62.5	100
	F_1 -score	89.8	65.38	62.22	75	88.89
	Accuracy _{mean}	76.67				
CNN	Precision	88.89	86.36	91.30	81.82	59.46
	Recall	100.00	79.17	87.50	37.50	91.67
	F_1 -score	94.12	82.61	89.36	51.43	72.13
	Accuracy _{mean}	79.17				
DHKELM	Precision	92.31	93.75	74.19	88.23	73.33
	Recall	100	62.5	95.83	62.5	91.67
	F_1 -score	96	75	83.63	73.17	81.48
	Accuracy _{mean}	82.5				
PSO-DHKELM	Precision	100	88.46	80.77	80.77	100
	Recall	95.83	95.83	87.5	87.5	79.17
	F_1 -score	97.87	92	84	84	88.37
	Accuracy _{mean}	89.17				
DBO-DHKELM	Precision	100	95.24	82.61	84.62	92.31
	Recall	100	83.33	79.17	91.67	100

分类模型	评价指标	正常状态	缓冲弹簧疲劳	基座松动	绝缘子松动	传动轴卡涩
DBO-DHKELM	F_1 -score	100	88.89	80.85	88	96
	Accuracy _{mean}	90.83				
IDBO-DHKELM	Precision	100	96	100	100	95.83
	Recall	100	100	100	95.83	95.83
	F_1 -score	100	97.96	100	97.87	95.83
	Accuracy _{mean}	98.33				

此外, IDBO-DHKELM 模型在五中状态分类上的精确率、召回率和 F_1 分数相较于其他六种模型均有显著提升, 表明其预测的准确程度、查全率及综合性能更为优越。

5.2 各模型训练时间对比

统计各模型的训练时间和故障诊断平均准确率, 不同模型性能比较见表3。

由表3可以看出, 尽管 DHKELM 模型嵌入了多个组合方法, 导致模型的训练时间相较于传统的 SVM、ELM 和 CNN 模型分别增加了 1.40、1.51 和 0.62 s, 但其平均准确率分别提升了 11.67%、5.83% 和 3.33%; 经融合多策略改进后的 IDBO-DHKELM 模型的训练时间, 相较于 PSO-DHKELM 和 DBO-DHKELM 模型增加了 0.42 s 和 0.29 s, 但其平均准确率分别提高了 9.16% 和 7.5%。对于故障诊断任务而言, 准确率的提升意味着在实际应用中能够更可靠地识别故障, 从而减少潜在的风险和损失。因此, 尽管 IDBO-DHKELM 模型在训练时间上有所增加, 但其在高压断路器机械故障诊断中的高准确率使其

表 3 不同模型性能比较

Tab.3 Comparison of the performance of the models

模型	训练时间/s	故障诊断平均准确率(%)
SVM	0.98	70.83
ELM	0.87	76.67
CNN	1.76	79.17
DHKELM	2.38	82.50
PSO-DHKEM	3.19	89.17
DBO-DHKEM	3.32	90.83
IDBO-DHKEM	3.61	98.33

成为了更优的选择。

6 结论

针对高压断路器机械故障诊断准确率较低的问题,本文提出了基于 IDBO-DHKELM 的故障诊断方法,通过实验验证可得出以下结论:

1) 对高压断路器典型工况的合闸振动信号进行 SVM 分解,提取功率谱熵构建特征向量,并利用 t -SNE 算法进行数据降维,得到 3 维的特征向量矩阵。降维后的特征向量,同一状态的样本表现出了明确的聚类特征,而不同状态的样本在 t -SNE 的映射结果中被分开,避免了信息冗余和高维数据容易影响模型诊断精度的问题。

2) IDBO 克服了 DBO 容易陷入局部最优和收敛精度较低的缺点。与 PSO 和 WOA 算法相比, IDBO 在收敛速度、寻优精度和稳定性方面均表现更优。

3) 实验验证结果表明,通过 IDBO 优化 DHKELM 模型的超参数,构建 IDBO-DHKELM 故障诊断模型,相较于传统分类模型 SVM、ELM、CNN 和 PSO-HKELM、DBO-DHKLEM,平均诊断准确率提高了 7.5%~27.5%,且在高压断路器五种状态分类上的精确率、召回率和 F_1 分数均有较大提升,验证了本文所提出方法的优越性和可靠性。

参考文献

[1] 刘亚魁,李红运,林天然,等.基于机器视觉的高压断路器机械特性测量方法[J].电工技术学报,2023,38(增刊1):222-230.
Liu Yakui, Li Hongyun, Lin Tianran, et al. Research on mechanical characteristic measurement method of

high voltage circuit breaker based on machine vision[J]. Transactions of China Electrotechnical Society, 2023, 38(S1): 222-230.

- [2] 刘会兰,许文杰,赵书涛,等.面向高压断路器故障分类的电流-振动信号类聚几何敏感特征优选方法[J].电工技术学报,2023,38(1):26-36.
Liu Huilan, Xu Wenjie, Zhao Shutao, et al. Optimization method of clustering geometric sensitive features of current vibration signals for fault classification of high voltage circuit breakers[J]. Transactions of China Electrotechnical Society, 2023, 38(1): 26-36.
- [3] Gao Wei, Wai R J, Qiao Supeng, et al. Mechanical faults diagnosis of high-voltage circuit breaker via hybrid features and integrated extreme learning machine[J]. IEEE Access, 2019, 7: 60091-60103.
- [4] Liu Qinzhe, Wang Xiaolong, Guo Zhaojing, et al. Research on circuit breaker operating mechanism fault diagnosis method combining global-local feature extraction and KELM[J]. Sensors, 2023, 24(1): 124.
- [5] Chu Yunfei, Feng Chunyan, Guo Caili, et al. Network embedding based on deep extreme learning machine[J]. International Journal of Machine Learning and Cybernetics, 2019, 10(10): 2709-2724.
- [6] Xue Jiankai, Shen Bo. Dung beetle optimizer: a new meta-heuristic algorithm for global optimization[J]. The Journal of Supercomputing, 2023, 79(7): 7305-7336.
- [7] 高伟,饶俊民,全圣鑫,等.不平衡小样本下多特征优化选择的生命体触电故障识别方法[J].电工技术学报,2024,39(7):2060-2071.
Gao Wei, Rao Junmin, Quan Shengxin, et al. Biological electric-shock fault identification method based on multi-feature optimization selection under unbalanced small sample[J]. Transactions of China Electrotechnical Society, 2024, 39(7): 2060-2071.
- [8] 鲁英达,张菁.基于改进猎人猎物算法的 VMD-KELM 短期负荷预测[J].电气工程学报,2023,18(4):228-238.
Lu Yingda, Zhang Jing. VMD-KELM short-term load forecasting based on improved hunter-prey optimizer[J]. Journal of Electrical Engineering, 2023, 18(4): 228-238.
- [9] 洪翠,连淑婷,郭谋发,等.经验小波变换在直流

- 配电系统故障检测中的应用[J]. 电机与控制学报, 2021, 25(12): 65-74.
- Hong Cui, Lian Shuting, Guo Moufa, et al. Application of empirical wavelet transform in fault detection of DC distribution system[J]. Electric Machines and Control, 2021, 25(12): 65-74.
- [10] 商立群, 侯亚东, 黄辰浩, 等. 基于 IDOA-DHKELM 的变压器故障诊断[J]. 高电压技术, 2023, 49(11): 4726-4735.
- Shang Liqun, Hou Yadong, Huang Chenhao, et al. Transformer fault diagnosis based on IDOA-DHKELM[J]. High Voltage Engineering, 2023, 49(11): 4726-4735.
- [11] Fang Zihan, Du Shide, Lin Xincan, et al. DBO-Net: differentiable bi-level optimization network for multi-view clustering[J]. Information Sciences, 2023, 626: 572-585.
- [12] Zhang Wen, Li Rui, Zhao Jiangpeng, et al. Miss-gradient boosting regression tree: a novel approach to imputing water treatment data[J]. Applied Intelligence, 2023, 53(19): 22917-22937.
- [13] 李丹丹, 吴宇翔, 朱聪聪, 等. 基于麻雀搜索与遗传算法的 J-A 磁滞模型参数辨识方法[J]. 高电压技术, 2022, 48(10): 4181-4188.
- Li Dandan, Wu Yuxiang, Zhu Congcong, et al. Parameter identification method for J-A hysteresis model based on the sparrow search and genetic algorithm[J]. High Voltage Engineering, 2022, 48(10): 4181-4188.
- [14] Li Mingying, Liu Zhilei, Song Hongxiang. An improved algorithm optimization algorithm based on RungeKutta and golden sine strategy[J]. Expert Systems with Applications, 2024, 247: 123262.
- [15] Zhang Ruibo, Su Jin, Feng Jinqian. An extreme learning machine model based on adaptive multi-fusion chaotic sparrow search algorithm for regression and classification[J]. Evolutionary Intelligence, 2024, 17(3): 1567-1586.
- [16] Suganthan P N, Hansen N, Liang J J, et al. Problem definitions and evaluation criteria for the CEC 2005 special session on real-parameter optimization. Nanyang Technological University[J]. Singapore, 2005, 30(5): 3201-3210.
- [17] 任宏宇, 余瑶怡, 杜雄, 等. 基于优化长短期记忆神经网络的 IGBT 寿命预测模型[J]. 电工技术学报, 2024, 39(4): 1074-1086.
- Ren Hongyu, Yu Yaoyi, Du Xiong, et al. IGBT lifetime prediction model based on optimized long short-term memory neural network[J]. Transactions of China Electrotechnical Society, 2024, 39(4): 1074-1086.
- [18] 何平, 雷勇, 杜佳耘, 等. 基于 EWT-FC 方法的氢-超级电容混合储能功率分配[J]. 电源学报, 2023, 21(5): 191-199.
- He Ping, Lei Yong, Du Jiayun, et al. Hydrogen-supercapacitor hybrid energy storage power distribution based on EWT-FC method[J]. Journal of Power Supply, 2023, 21(5): 191-199.
- [19] 陈诺, 吕干云, 叶加星. 基于 SVM 级联决策树的复合电能质量扰动识别[J]. 电气工程学报, 2023, 18(2): 149-156.
- Chen Nuo, Lü Ganyun, Ye Jiaying. Recognition of complex PQ disturbances based on SVM cascaded decision tree[J]. Journal of Electrical Engineering, 2023, 18(2): 149-156.

作者简介

范兴明 男, 1978 年生, 教授, 博士生导师, 研究方向为智能化电器和高电压新技术。

E-mail: fanxm_627@163.com

张鑫 女, 1976 年生, 高级实验师, 研究方向为智能化电器。

E-mail: zhangxin_wt@163.com (通信作者)

Fault Diagnosis of High Voltage Circuit Breaker Based on Improved Dung Beetle Optimizer Algorithm Deep Hybrid Kernel Extreme Learning Machine

Fan Xingming Xu Honghua Zhang Sishun Li Tao Jiang Yanjun Zhang Xin

(Department of Electrical Engineering & Automation Guilin University of Electronic and Technology
Guilin 541004 China)

Abstract This paper proposes a fault diagnosis method based on an improved dung beetle optimization algorithm (IDBO) to solve the problem of low accuracy of mechanical fault diagnosis of high-voltage circuit breakers. Tent chaotic mapping, a golden sine strategy, and adaptive t -distribution perturbation are incorporated to optimize a deep hybrid kernel extreme learning machine (DHKELM).

Firstly, this paper takes a TY-1S-12/630-16 single-phase vacuum high-voltage circuit breaker as the research object and builds a platform for collecting high-voltage circuit breaker closing vibration signals. Five operating conditions are simulated: normal state, cushion spring fatigue, base looseness, insulator looseness, and drive shaft jam. The laser vibrometer's sampling time and frequency are set to 1 000 ms and 78 125 Hz. 60 groups of samples for each condition of the high-voltage circuit breaker are collected, totaling 300 sets of samples.

Secondly, the successive variational modal decomposition (SVMD) is used to decompose the acquired signals, the seven IMF components with different center frequencies are obtained after decomposition, and the power spectral entropy of each IMF component is extracted to construct the feature vector matrix. Data dimensionality reduction of the feature vectors is carried out using the t -distribution-stochastic neighborhood embedding algorithm (t -SNE) to obtain 300 by 3-dimensional feature vectors. After dimensionality reduction by t -SNE, the samples of the same state show clear clustering characteristics, while the samples of different states are separated in the mapping results of t -SNE. Hence, the problems of information redundancy and high-dimensional data are avoided.

Then, by introducing three optimization strategies—fusion Tent chaotic mapping, golden sine strategy, and adaptive t -distribution perturbation, the improved dung beetle optimization (IDBO) algorithm is proposed. The IDBO algorithm optimizes the parameters of the DHKELM for constructing the IDBO-DHKELM high-voltage fault diagnosis model. The unimodal and multimodal functions from the CEC2005 test suite are selected for performance testing. The improved IDBO algorithm is compared with traditional PSO, WOA, and DBO algorithms, verifying its superior convergence speed, optimization precision, and stability in finding the optimal solution.

Finally, a platform is built to simulate mechanical failures of high-voltage circuit breakers. The fault diagnosis results show that the proposed method's fault diagnosis accuracy reaches 98.33%, and the average accuracy of the classification of the DHKELM model is improved by 11.67%, 5.83%, and 3.33%, respectively, compared with that of the traditional SVM, ELM, and CNN models. The DHKELM model improves the average classification accuracy by 9.16% and 7.5% compared with PSO-DHKELM and DBO-DHKELM models, and the precision rate, recall rate, and $F_{1\text{-score}}$ are greatly improved.

Keywords: High-voltage circuit breaker, improved dung beetle optimizer algorithm, deep hybrid kernel limit learning machine, fault diagnosis, successive variational modal decomposition

(编辑 崔文静)