



DOI:10.13364/j.issn.1672-6510.20240113

数字出版日期: 2024-11-05; 数字出版网址: <http://link.cnki.net/urlid/12.1355.N.20241105.1348.002>

基于 VMD-IBKA-ELM 的电力电子电路软故障诊断

陈苗^{1,2}, 姜媛媛^{1,2}

(1. 安徽理工大学电气与信息工程学院, 淮南 232001;

2. 安徽理工大学环境友好材料与职业健康研究院, 芜湖 241003)

摘要: 针对传统电力电子电路在软故障诊断领域的特征区分度低、诊断效率低等一系列问题, 提出一种变分模态分解(VMD)结合改进的黑翅鸢搜索算法(IBKA)优化极限学习机(ELM)的故障诊断方法。首先, 利用 VMD 技术将采集到的故障信号进行分解重构, 并得到故障诊断的特征向量。其次, 用改进后的黑翅鸢搜索算法对 ELM 的参数进行优化, 得到 IBKA-ELM 分类模型; IBKA 采用 Sine 映射初始化种群, 随机选择 3 个不同的个体进行差分变异操作, 更新领导者位置, 在领导者位置更新处引入自适应惯性权重因子, 可有效提高算法的寻优能力和收敛速度。最后, 通过 150 W 的 Boost 电路对本文方法进行实验验证。实验结果显示, VMD 结合 IBKA-ELM 的故障诊断方法在实际诊断中的精度均达到 99% 以上。

关键词: 软故障诊断; 变分模态分解; 黑翅鸢搜索算法; 极限学习机; DC-DC 电路

中图分类号: U226.8⁺1; TN108.7

文献标志码: A

文章编号: 1672-6510(2024)06-0057-09

Soft Fault Diagnosis of Power Electronic Circuits Based on VMD-IBKA-ELM

CHEN Miao^{1,2}, JIANG Yuanyuan^{1,2}

(1. College of Electrical and Information Engineering, Anhui University of Science and Technology, Huainan 232001,

China; 2. Institute of Environment-Friendly Materials and Occupational Health, Anhui University of Science and

Technology, Wuhu 241003, China)

Abstract: To address the problems of low feature differentiation and low diagnostic efficiency of traditional power electronic circuits in the field of soft fault diagnosis, a fault diagnosis method based on variational mode decomposition (VMD) combined with improved black-winged kite search algorithm (IBKA) to optimize extreme learning machine (ELM) is proposed in this article. Firstly, the collected fault signal is decomposed and reconstructed by using VMD technology, and the fault diagnosis feature vector is obtained. Secondly, the improved BKA is used to optimize the ELM parameters, and the IBKA-ELM classification model is obtained; IBKA initializes the population by Sine mapping, randomly selects three different individuals for differential mutation operation, updates the leader position, and introduces adaptive inertial weight factor in the leader position update, which can effectively improve the optimization ability and convergence speed of the algorithm. Finally, the proposed method was verified by a 150 W Boost circuit. The experimental results showed that the accuracy of VMD combined with IBKA-ELM in the actual diagnosis reached more than 99%.

Key words: soft fault diagnosis; variational mode decomposition; black-winged kite search algorithm; extreme learning machine; DC-DC circuit

收稿日期: 2024-05-16; 修回日期: 2024-09-06

基金项目: 安徽省重点研究与开发计划项目(202104g01020012); 安徽理工大学环境友好材料与职业健康研究院研发专项基金资助项目(ALW2020YF18)

作者简介: 陈苗(2002—), 女, 安徽芜湖人, 硕士研究生; 通信作者: 姜媛媛, 教授, jyyLL672@163.com

引文格式:

陈苗,姜媛媛. 基于 VMD-IBKA-ELM 的电力电子电路软故障诊断[J]. 天津科技大学学报, 2024, 39(6): 57-65.

CHEN M, JIANG Y Y. Soft fault diagnosis of power electronic circuits based on VMD-IBKA-ELM[J]. Journal of Tianjin university of science & technology, 2024, 39(6): 57-65.

随着电力电子技术和材料技术的快速发展,电力电子电路被广泛应用于各个领域,如电动汽车、智能电网及现代国防等^[1]。这些电路的越发复杂导致故障概率随之增加。由于电路故障可能引发严重的经济和安全问题,因此及时准确地诊断故障原因至关重要。目前存在多种电路故障诊断方法^[2-3],这些方法主要针对电路的硬故障。电路软故障(如电力器件参数的逐渐衰减等)虽然发展缓慢,但未及时处理可能会转变为硬故障,并带来严重后果。软故障特征不明显且难以诊断,相关研究较少^[4]。

电力电子电路故障诊断的核心为提取故障信号特征和故障分类。包金山等^[5]使用核主成分分析(kernel principal component analysis, KPCA)对待选特征进行特征融合和低维敏感特征提取,但是使用过程中 KPCA 的计算复杂度和空间复杂度均较高。吴怡等^[6]引入一种新的局部峭度比指标,确定最优滤波器长度,用于计算基于高斯平稳模型的估计阶数,并构建分数阶循环平稳盲反卷积,提取故障特征能力有效加强,但是仅对单一故障的诊断提供了一定的参考价值。胡勇等^[7]提出的经验模态分解(empirical mode decomposition, EMD)对非线性和非平稳信号问题有很强的敏锐性,适用于提取复杂信号中的局部特征,但容易产生模式混叠和边界效应。本文使用可避免模式混叠的变分模态分解(variational modal decomposition, VMD)进行特征提取,其可靠的鲁棒性和良好的频率分离能力可以有效处理非平稳信号问题。

智能算法正在被广泛运用于故障诊断领域,尤其是卷积神经网络(convolutional neural network, CNN)、支持向量机(support vector machine, SVM)、极限学习机(extreme learning machine, ELM)、反向传播神经网络(back propagation neural network, BP)等技术的灵活使用,有效提高了诊断的效率和准确性,大幅提高了设备和系统的可靠性和稳定性。崔鹏飞等^[8]提出的 CNN 结合聚合分类器元学习框架(model-agnostic aggregate classifier meta-learning, MAACML)的故障诊断方法,虽然泛化能力较好,但是计算成本较高且对初始学习率等超参数非常敏感。张传雷等^[9]提出基于最优间隔分布的最小二乘支持向量机模型,该模型具有高效的非线性分类能力和

强大的泛化能力,但是该方法需要预设参数,并且计算复杂度高,不适用于处理大规模数据集。Xiao 等^[10]将甲虫优化算法与 BP 相结合,虽然 BP 精度高,但学习速度慢,参数设置多。综合考虑这些智能算法的优缺点,本文使用的 ELM 不仅训练速度快、泛化能力强,而且实现简单,不需要调节多个超参数。它在处理非线性问题时表现出色,更适用于复杂数据的分类和回归任务。

基于以上研究,本文首先利用 VMD 对采集到的故障信号进行分解,生成本征模态函数(IMF)分量,并对这些 IMF 分量进行降噪、滤波、重构并提取 12 维特征;其次,对原始黑翅鸢搜索算法(BKA)优化并将改进后的 BKA (IBKA)在单峰和多峰基准函数上进行对比,评估改进后的 BKA 的性能;然后,通过 IBKA 对 ELM 网络优化得到 IBKA-ELM 诊断模型;最后,对 150 W 的 Boost 电路中的电解电容和普通二极管分别进行实验验证。

1 特征信号提取

VMD 是一种高效的信号处理技术,它通过解决优化问题自适应地将信号分解为具有窄带频率的固有模态函数,适用于处理非线性和非平稳信号。VMD 的核心理念是利用变分求解方法进行信号分析。这种方法能将信号拆分为 K 个内在 IMF,并为每个 IMF 找到最佳的中心频率和有限的带宽,实现信号频率和带宽的有效分离,有效防止了模态混叠现象的发生。

电力电子电路器件的软故障包括参数漂移、噪声干扰、老化效应、电源质量问题、控制信号异常和软件故障等。这些故障不涉及器件的物理损坏,但会影响电路的性能和正常运行。例如,电阻或电容等元件参数的变化、外部或内部噪声干扰、接插件接触电阻增大、元器件老化、电源电压波动、控制信号失真以及嵌入式系统等均可能导致电路工作不稳定。本文主要考虑电力电子电路中的 DC-DC 电路,并使用表 1 中的 10 种常用参数作为 DC-DC 电路的故障特征参数,表 1 中的 $X(i)$ 表示信号序列, $i = 1, 2, \dots, N$ 。其中:表格中均值、方差、标准差、峰值和均方根为有

量纲参数,直接反映了信号的物理特性;表格中峰值因子、峭度因子、脉冲因子、波形因子和裕度因子为无量纲参数,抗干扰能力较强,能够在噪声的影响下保持参数的稳定性。在实际应用中,同时采用有量纲参数和无量纲参数可以更全面地分析信号,提高故障诊断的准确性。

表1 常用时域参数

Tab. 1 Common time domain parameters

时域参数	数学表达式	时域参数	数学表达式
均值	$x_1 = \frac{1}{N} \sum_{i=1}^n X(i)$	峰值因子	$x_6 = x_4 / x_5$
方差	$x_2 = \frac{1}{N} \sum_{i=1}^n (X(i) - x_1)^2$	峭度因子	$x_7 = \frac{1}{N} \sum_{i=1}^n (X(i) - x_1)^4$
标准差	$x_3 = \sqrt{\frac{1}{N} \sum_{i=1}^n (X(i) - x_1)^2}$	脉冲因子	$x_8 = x_4 / x_1$
峰值	$x_4 = \max X(i) $	波形因子	$x_9 = x_8 / x_6$
均方根	$x_5 = \sqrt{\frac{1}{N} \sum_{i=1}^n X^2(i)}$	裕度因子	$x_{10} = \frac{x_4}{\left(\frac{1}{N} \sum_{i=1}^n \sqrt{ X(i) }\right)^2}$

2 黑翅鸢算法及改进

2.1 黑翅鸢算法

Wang 等^[11]受黑翅鸢攻击和迁徙行为的启发,提出一种名为黑翅鸢优化算法(black-winged kite algorithm, BKA)的新型群智能优化算法,该算法将Cauchy 突变策略和 Leader 策略进行结合,一定程度上提高了算法的全局搜索能力和收敛速度。BKA 主要分为攻击行为和迁移行为两个部分。

2.1.1 攻击行为

黑翅鸢攻击行为的数学模型为

$$X_{t+1}^{i,j} = \begin{cases} X_t^{i,j} + n(1 + \sin(r)) \times X_t^{i,j} & r > 0.9 \\ X_t^{i,j} + n \times (2r - 1) \times X_t^{i,j} & r \leq 0.9 \end{cases} \quad (1)$$

$$n = 0.05 \times e^{-2 \times \left(\frac{t}{T}\right)^2} \quad (2)$$

式中: $X_t^{i,j}$ 、 $X_{t+1}^{i,j}$ 分别表示第 i 只黑翅鸢在第 j 维中的位置信息; r 表示 (0,1) 中的随机数; T 表示最大迭代次数; t 表示当前迭代次数; n 表示缩放因子,控制位置更新的幅度。

2.1.2 迁移行为

黑翅鸢迁移行为的数学模型为

$$X_{t+1}^{i,j} = \begin{cases} X_t^{i,j} + C(0,1) \times (X_t^{i,j} - L_t^j) & F_i < F_{r_i} \\ X_t^{i,j} + C(0,1) \times (L_t^j - m \times X_t^{i,j}) & \text{其他} \end{cases} \quad (3)$$

$$m = 2 \times \sin\left(r + \frac{\pi}{2}\right) \quad (4)$$

式中: L_t^j 表示到目前为止,第 t 次迭代的第 j 维中黑翅鸢的领先得分者; F_i 表示任意黑翅鸢在第 t 次迭代中获得的第 j 维中的位置信息; F_{r_i} 表示第 t 次迭代中任意黑翅鸢在第 j 维随机位置的适应度; $C(0,1)$ 表示柯西随机数; m 表示修正因子。

一维柯西分布是具有两个参数的连续概率分布,概率密度函数为

$$f(x, \delta, \mu) = \frac{1}{\pi} \frac{\delta}{\delta^2 + (x - \mu)^2} \quad -\infty < x < \infty \quad (5)$$

当 $\delta = 1$, $\mu = 0$ 时,概率密度函数为

$$f(x, \delta, \mu) = \frac{1}{\pi} \frac{1}{x^2 + 1} \quad -\infty < x < \infty \quad (6)$$

2.2 改进的 BKA

BKA 作为一种元启发式算法,同样存在对问题领域的依赖性较强、可能陷入局部最优解、计算复杂度较高、参数设置困难等问题。针对这些问题,本文提出 3 种改进策略。

2.2.1 Sine 混沌映射

初始化种群能够确保算法在搜索空间中具有足够的探索性和多样性,促进算法在早期阶段快速收敛获得较优解,并提高算法的全局搜索能力,避免算法陷入局部最优解。在种群初始化时引入混沌运动,能够有效帮助种群在初始阶段更好地探索搜索空间,从而增加了算法的全局搜索能力,有助于避免陷入局部最优解,提高了算法的收敛性和搜索效率。经典的混沌映射模型有 Tent 映射模型和 Logistic 映射模型等,但这两类模型折叠次数有限,与之相比,折叠次数无限的 Sine 映射模型混沌性更显著^[12]。

Sine 映射的定义为

$$x_{k+1} = a \sin(\pi x_k) \quad (7)$$

式中: a 为控制参数,取值范围在区间 [0, 1] 内,通常情况下, a 越接近于 1,混沌效果越显著; k 为非负正整数。

取 $a = 0.99$, 迭代次数为 1000 次, Sine 映射的混沌分布如图 1 所示,当迭代到一定次数时,系统将遍历整个搜索区间。Sine 混沌映射的频数如图 2 所示,在相同迭代次数时,各区间分布搜索更加均衡,改进了其他混沌映射中存在的边缘搜索问题。

2.2.2 自适应权重因子

自适应权重因子^[13]的特点包括灵活性好、适应性强、全局优化能力强、参数设置少和鲁棒性强等。




图1 Sine 映射的混沌分布图

Fig. 1 Chaotic distribution of Sine mapping




图2 Sine 混沌映射的频数

Fig. 2 Frequency of Sine chaotic mapping

在原算法基础上,引入自适应权重因子,能够提升算法求最优解的能力,助力算法摆脱局部最优解的束缚,并且使算法在寻找最优解的过程中有更高的收敛精度。自适应权重因子 ω 为

$$\omega = \frac{\exp\left(2\left(1-\frac{t}{T}\right)\right) - \exp\left(-2\left(1-\frac{t}{T}\right)\right)}{\exp\left(2\left(1-\frac{t}{T}\right)\right) + \exp\left(-2\left(1-\frac{t}{T}\right)\right)} \quad (8)$$

式中: t 表示当前迭代次数, T 为最大迭代次数。

当 $F_i < F_{r_i}$ 时,黑翅鸢领导者位置更新为

$$X_{i,t+1}^{i,j} = X_t^{i,j} + C(0,1) \times \omega \times (X_t^{i,j} - L_t^j) \quad (9)$$

当 $F_i \geq F_{r_i}$ 时,黑翅鸢领导者位置保持不变。

2.2.3 随机差分扰动策略

为了解决原始黑翅鸢算法在中后期将局部最优解误认为全局最优解并因此陷入局部最优的问题,本文提出一种随机差分扰动策略。该策略通过对当前领导者的位置执行随机差分扰动,生成新的领导者位置。这种方法不仅增强了群体的多样性,还帮助算法跳出局部最优,从而提高了整体的搜索效果。具体公式为

$$V_{i,t+1} = X_{r_1,t} + F \cdot (X_{r_2,t} - X_{r_3,t}) \quad (10)$$

式中: F 为缩放因子,取值范围在区间[0.5, 1.0]内。

采用贪心规则确定经过变异后的新位置是否优

于原位置。对两个位置的适应度进行比较,如果新位置表现出更好的适应度,则用新位置代替原来的位置,即 $X_{r,t+1} = V_{i,t+1}$ 。

综上所述,BKA 改进后操作步骤如下:

步骤(1):初始化算法参数。

步骤(2):引入 Sine 混沌映射,初始化种群。

步骤(3):计算种群中所有个体的适应度 $f(X_i)$,并选择适应度最好的个体作为领导者,即 $X_L = X(\text{find}(f_{\text{best}} = f(X_i)))$ 。

步骤(4):随机选择 3 个不同的个体进行差分变异操作,并检查边界条件。若变异后的个体适应度优于原先个体,则替换原个体。

步骤(5):根据概率 p 和当前迭代步骤的特定函数更新位置,并检查边界条件。

步骤(6):引入自适应权重 ω ,跳出局部最优。

步骤(7):判断是否满足要求。若满足,输出最优解,反之返回步骤(3)。

2.3 性能评估

群智能优化算法是受自然界中生物群体行为启发的计算方法。近年来,常见的群智能优化算法有麻雀优化算法(SSA)^[14]和 Harris 鹰算法(HHO)^[15]等。为了验证 IBKA 的有效性,将改进后的 BKA 与飞蛾扑火优化算法(MFO)、HHO、SSA 以及 BKA 进行对比,这些算法设定的部分参数见表 2。

表 2 算法部分参数

Tab. 2 Some parameters of the algorithm

算法	部分参数
MFO	飞行半径 $b = 1$, 火焰数量 $N = 50$, 收敛常数 θ 取值 $[-1, 1]$
HHO	Levy 飞行参数 $\beta = 1.5$, 跳跃距离 J 取值 $[0, 2]$
SSA	发现者比例为 0.3, 警报者比例为 0.2, 预警值为 0.7
BKA	概率阈值 $p = 0.9$
IBKA	同 BKA, 控制参数 $a = 0.99$, 缩放因子 F 取值 $[0.5, 1.0]$

使用表 3 中的 8 种函数进行测试,前 4 种为单峰函数,后 4 种为多峰函数。设定种群数量为 30,最大迭代次数为 500 次。


部分函数收敛曲线对比如图 3 所示,由 F_1 、 F_3 函数的收敛曲线图可知,相较于初始 BKA 算法,IBKA 具有更高的收敛精度,寻优能力大幅度增强;同样,在同等的迭代次数下,IBKA 收敛精度更高,寻优能力更强。

由 F_6 、 F_8 函数的收敛曲线图可知,在收敛精度相同时,IBKA 只需要更少的迭代次数就能够获得最优解。综合所有收敛曲线图的收敛特征可知,改进后的 BKA 的收敛性能有较大的提高。


表 3 基准测试函数

Tab. 3 Benchmark functions


编号	函数	取值范围	维度	最小值
F_1	$F_1(x) = \sum_{i=1}^n x_i^2$	$[-100, 100]$	30	0
F_2	$F_2(x) = \sum_{i=1}^n x_i + \prod_{i=1}^n x_i $	$[-10, 10]$	30	0
F_3	$F_3(x) = \sum_{i=1}^{n-1} [100(x_{i+1} - x_i)^2 + (x_i - 1)^2]$	$[-30, 30]$	30	0
F_4	$F_4(x) = \sum_{i=1}^n ix_i^4 + \text{random}[0,1]$	$[-1.28, 1.28]$	30	0
F_5	$F_5(x) = \sum_{i=1}^n [x_i^2 - 10 \cos(2\pi x_i) + 10]$	$[-5.12, 5.12]$	30	0
F_6	$F_6(x) = -20 \exp\left(-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}\right) - \exp\left[\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i)\right] + 20 + e$	$[-32, 32]$	30	0
F_7	$F_7(x) = \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$	$[-600, 600]$	30	0
F_8	$F_8(x) = \frac{\pi}{n} \left\{ 10 \sin(\pi y_1) + \sum_{i=1}^{n-1} (y_i - 1)^2 [1 + 10 \sin^2(\pi y_{i+1})] + (y_n - 1)^2 \right\} + \sum_{i=1}^n u(x_i, 10, 100, 4)$	$[-50, 50]$	30	0




(a) F_1 函数收敛图



(b) F_3 函数收敛图



(c) F_6 函数收敛图



(d) F_8 函数收敛图

图 3 部分函数收敛曲线对比图

Fig. 3 Comparison of convergence curve for partial functions

3 IBKA 优化 ELM

3.1 ELM

ELM 是一种单隐层前馈神经网络, 它通过求解线性方程组快速完成训练, 增强了泛化能力, 在训练速度和泛化能力上显著优于传统神经网络。本文提出一种基于 IBKA-ELM 诊断模型的故障诊断方法。

ELM 数学表达式为

$$Y_i = f_i(x) = \sum_{i=1}^l \beta_i g(w_i \cdot X_i + b_i) \quad i=1,2,\dots,N \quad (11)$$

式中: w_i 表示输入权值, b_i 表示隐含层偏差值, β_i 表示输出权值, X_i 表示输入向量, Y_i 表示输出向量, g 表示激活函数, l 表示隐含层神经元数量。

ELM 网络结构如图 4 所示。




图4 ELM网络结构

Fig. 4 ELM network structure

3.2 IBKA-ELM诊断模型

ELM 随机产生的输入权值和隐藏层节点数会影响算法的泛化能力, IBKA 通过引入 Sine 混沌映射初始化种群、自适应权重因子和随机差分扰动策略, 优化 ELM 的输入权重和隐含层偏置, 增强了算法的全局搜索能力和收敛速度, 从而提高了 ELM 在故障诊断中的分类性能和精度。优化流程图如图 5 所示。




图5 IBKA优化ELM流程图

Fig. 5 Flowchart of optimizing ELM by IBKA

4 DC-DC 电路软故障诊断实例分析

4.1 电路结构和软故障模式设置

选用由 UC3843 芯片控制的 150 W 的 Boost 电路为实验对象, 该电路的输入电压为 12 V, 输出电压为 24 V, 额定功率为 150 W。电路接入的负载电阻为 100 Ω, 负载功率为 50 W。Boost 电路是一种通过周期性地开关电感元件和电容元件实现电压升压的电路。实验平台如图 6 所示, Boost 电路原理图如图 7 所示。

在负载电流过大、电压波动频繁和长期使用等因

素的综合作用下, 实际工业环境中电力电子电路中电解电容的故障率可高达 60%^[16]。实验选用 PCI8335A 数据采集卡进行信号测试及采集。PCI8335A 的 A/D 分辨率为 16 位, 采样频率为 250 kHz, 具有 32 路(单)/16 路(差分)模拟输入以及 4 路模拟输出和 16 路数字量输入、16 路数字量输出。由于 DC-DC 电路输出电压为 24 V, 超出数据采集卡量程(-10 ~ 10 V), 采用电阻分压模块降压。150 W Boost 电路连接图如图 8 所示。本文选取标称值为 1 000 μF 的电解电容 C₁ 和 C₅, 根据其退化程度共设定 16 种软故障模式(见表 4), 包括 6 种单个电容的软故障(f12、f13、f14、f21、f31、f41)以及 9 种两个电容的软故障模式(f22、f23、f24、f32、f33、f34、f42、f43、f44), f11 为正常状态。选择 4 个测试点的电压信号为故障信号, 分别为输入电压(测试点 1)、输出电压(测试点 2)、MOS 管漏极电压(测试点 3)、MOS 管源极电压(测试点 4)。在 f11、f21、f31、f41 故障模式下, 测试点 2 处的电压波形如图 9 所示, 根据图 9 可以看出, 电容在正常状态下和非正常状态下的电压波形差异性不大, 因此采用 VMD 进行故障特征提取, 提高故障分类的准确性。采集 50 组数据, 共 2 000 个采样点。




图6 实验平台

Fig. 6 Experimental platform




图7 Boost电路原理图

Fig. 7 Schematic diagram of Boost circuit

设定初始导通压降为 0.7 V、初始反向漏电流 1 μA 的普通二极管^[17]继续研究, 根据其退化程度共设定 5 种软故障模式(表 5), 其中 f1 为正常模式。




图 8 150 W Boost 电路连接图

Fig. 8 150 W Boost circuit connection diagram

表 4 电容故障模式

Tab. 4 Capacitor failure modes

故障模式	C_1 (C_5) 电容/ μF	C_1 (C_5) 退化等级/%
f11	988 (916)	0 ~ 10 (0 ~ 10)
f12	988 (887)	0 ~ 10 (> 10 ~ 20)
f13	988 (653)	0 ~ 10 (> 30 ~ 40)
f14	988 (554)	0 ~ 10 (> 40 ~ 50)
f21	864 (916)	> 10 ~ 20 (0 ~ 10)
f22	864 (887)	> 10 ~ 20 (> 10 ~ 20)
f23	864 (653)	> 10 ~ 20 (> 30 ~ 40)
f24	864 (554)	> 10 ~ 20 (> 40 ~ 50)
f31	655 (916)	> 30 ~ 40 (0 ~ 10)
f32	655 (887)	> 30 ~ 40 (> 10 ~ 20)
f33	655 (653)	> 30 ~ 40 (> 30 ~ 40)
f34	655 (554)	> 30 ~ 40 (> 40 ~ 50)
f41	546 (916)	> 40 ~ 50 (0 ~ 10)
f42	546 (887)	> 40 ~ 50 (> 10 ~ 20)
f43	546 (653)	> 40 ~ 50 (> 30 ~ 40)
f44	546 (554)	> 40 ~ 50 (> 40 ~ 50)

4.2 实验分析

实验在 MATLAB2023a 中进行算法编程与分析。根据经验设定惩罚因子 $\alpha = 2000$, 判别精度 $\epsilon = 10^{-7}$, $K = 7$, 并通过 VMD 处理获得所有故障模式下 4 个测点的特征向量, 共 48 维。按照 4 : 1 的比例划分为训练集和测试集, 导入 IBKA-ELM 诊断模型, 故障诊断过程如图 10 所示。

为验证 IBKA-ELM 诊断模型的性能, 将其与传统的 ELM、BKA-ELM、MFO-ELM、HHO-ELM、SSA-ELM 进行对比实验。实验过程中, 种群规模均为 20, 最大迭代次数均为 50。当普通二极管^[18]保持在 f1 正常模式下, 各诊断模型诊断实验结果见表 6。




图 9 f11、f21、f31、f41 故障模式下测点 2 的电压波形
Fig. 9 Voltage waveform of measuring point 2 in f11, f21, f31 and f41 fault modes

表 5 普通二极管故障模式

Tab. 5 Common diode failure modes

故障模式	导通压降/V	反向漏电流/ μA	退化程度/%
f1	0.71	1.2	0 ~ 5
f2	0.75	4.5	> 5 ~ 10
f3	0.79	8.0	> 10 ~ 15
f4	0.82	11.0	> 15 ~ 20
f5	0.85	15.0	> 20 ~ 25




图 10 故障诊断流程图

Fig. 10 Trouble shooting flow chart

表 6 各诊断模型诊断准确率(电容)

Tab. 6 Diagnostic accuracy of each diagnostic model (capacitor)

诊断模型	最低准确率/%	最高准确率/%	平均准确率/%
ELM	94.583	98.750	96.458
MFO-ELM	96.250	100.000	98.452
SSA-ELM	97.500	99.167	98.482
HHO-ELM	96.667	99.583	98.274
BKA-ELM	97.500	99.583	98.601
IBKA-ELM	98.750	100.000	99.256

当电解电容 C_1 、 C_5 均保持在 f11 正常模式下,各诊断模型诊断实验结果见表 7。

表 7 各诊断模型诊断准确率(二极管)

Tab. 7 Diagnostic accuracy of each diagnostic model (diode)

诊断模型	最低准确率/%	最高准确率/%	平均准确率/%
ELM	95.642	97.667	96.354
MFO-ELM	97.163	98.788	97.992
SSA-ELM	98.291	100.000	99.065
HHO-ELM	97.163	99.047	98.744
BKA-ELM	98.614	99.677	99.281
IBKA-ELM	99.710	100.000	99.913

在相同实验环境中连续实验 30 次,取平均值并进行分析。由表 6 可知,BKA-ELM 的诊断准确率为 98.601%, IBKA-ELM 的诊断准确率为 99.256%, IBKA-ELM 的诊断准确率相比于 BKA-ELM 提升了 0.655%; SSA-ELM 的诊断准确率为 98.482%, HHO-ELM 的诊断准确率为 98.274%, MFO-ELM 的诊断准确率为 98.452%, 相比之下 IBKA-ELM 诊断模型的诊断精度更高。由表 7 可知,BKA-ELM 的诊断准确率为 99.281%, IBKA-ELM 的诊断准确率为 99.913%, IBKA-ELM 的诊断准确率相比于 BKA-ELM 提升了 0.632%; SSA-ELM 的诊断准确率为 99.065%, HHO-ELM 的诊断准确率为 98.744%, MFO-ELM 的诊断准确率为 97.992%, 相比之下, IBKA-ELM 诊断模型同样具有优越性,体现了算法的通用性和覆盖性。综上所述,本文算法在 DC-DC 电路软故障诊断领域有一定的参考价值。

5 结 语

为了解决电力电子电路软故障诊断中特征区分度低、诊断困难等问题,本文提出一种结合 VMD 和改进的 BKA 优化 ELM 分类器的故障诊断方法。利用变分模态分解(VMD)对采集到的故障信号分解生成模态函数(IMF)分量,对 IMF 分量降噪、滤波、重构并提取 12 维特征,以此获得能够更加准确反映电路所处状态的信息。利用本文提出的策略对原始 BKA 进行优化,提升算法性能。通过与多种群智能算法对基准函数进行对比测试,以此证明改进后算法性能的优越性。将 IBKA 对 ELM 的输入权重和隐含层阈值寻优,与原始 ELM 和多种优化算法优化 ELM 的模型进行比较,实验结果证实 IBKA-ELM 在电力电子电路软故障诊断中准确率最高,诊断结果更加均衡,证明本文方法的可行性。本文方法提升了 DC-DC 电路故障诊断的准确性,为 DC-DC 电路故障诊断提供了一定的参考。

参考文献:

[1] KHAN S S, WEN H. A comprehensive review of fault diagnosis and tolerant control in DC-DC converters for DC microgrids[J]. IEEE Access, 2021, 9: 80100-80127.

[2] JIANG D Y, WANG Y G. Fault diagnosis of power electronic circuits based on adaptive simulated annealing particle swarm optimization[J]. Computers, materials & continua, 2023, 76(1): 295-309.

[3] WANG W C, KOU L, YUAN Q D, et al. An intelligent fault diagnosis method for open-circuit faults in power-electronics energy conversion system[J]. IEEE Access, 2020, 8: 221039-221050.

[4] NIE L, REN Y Z, WU R H, et al. Sensor fault diagnosis, isolation, and accommodation for heating, ventilating, and air conditioning systems based on soft sensor[J]. Actuators, 2023, 12(10): 389-407.

[5] 包金山, 杨定坤, 张靖, 等. 基于特征提取与 INGO-SVM 的变压器故障诊断方法[J]. 电力系统保护与控制, 2024, 52(7): 24-32.

[6] 吴怡, 王金海, 杨建伟, 等. 基于自适应分数阶循环平稳盲反卷积的滚动轴承故障诊断方法[J/OL]. 北京交通大学学报, 1-13[2024-06-05]. <http://kns.cnki.net/kcms/detail/11.5258.U.20240416.1023.002.html>.

[7] 胡勇, 李孝忠. 基于 EMD 和改进 TCN 的滚动轴承剩

- 余寿命预测方法[J]. 天津科技大学学报, 2023, 38(6): 62-68.
- [8] 崔鹏飞, 亚森江·加入拉, 许晨星, 等. 基于元学习聚合分类器的流程工业故障诊断[J]. 制造技术与机床, 2024(5): 27-34.
- [9] 张传雷, 武孟艳, 可婷, 等. 基于最优间隔分布的最小二乘支持向量机[J]. 天津科技大学学报, 2023, 38(2): 56-62.
- [10] XIAO M H, ZHANG W, WEN K, et al. Fault diagnosis based on BP neural network optimized by beetle algorithm[J]. Chinese journal of mechanical engineering, 2021, 34: 119.
- [11] WANG J, WANG W C, HU X X, et al. Black-winged kite algorithm: a nature-inspired meta-heuristic for solving benchmark functions and engineering problems[J]. Artificial intelligence review, 2024, 57(4): 98.
- [12] 马乐杰, 邹德旋, 李灿, 等. 融合差分进化和 Sine 混沌的改进粒子群算法[J]. 计算机工程与应用, 2024, 60(19): 80-96.
- [13] ZHANG Q Q, WANG D Q, GAO L F. Research on the inverse kinematics of manipulator using an improved self-adaptive mutation differential evolution algorithm[J]. International journal of advanced robotic systems, 2021, 18(3): 17298814211014413.
- [14] 刘涛, 蒙学强. 改进麻雀搜索算法的入侵检测特征选择[J]. 计算机工程与设计, 2024, 45(4): 989-996.
- [15] 李雨恒, 高尚, 孟祥宇. 基于精英引导的改进哈里斯鹰优化算法[J]. 计算机工程与科学, 2024, 46(2): 363-373.
- [16] 李嘉诚, 任磊, 秦岭, 等. 直流微电网 Buck 变换器输出电容的故障诊断[J/OL]. 电源学报, 1-15[2024-06-13]. <http://kns.cnki.net/kcms/detail/12.1420.TM.20231220.0931.004.html>.
- [17] DU Q X, GAO L, LIU W, et al. Diode open-circuit fault research on the parallel-connected 24-pulse rectifier with DC-side passive harmonic reduction circuit[J]. IEEE Transactions on power electronics, 2021, 37(1): 485-497.
- [18] ZHANG M Y, ZHANG Z B, LI Z, et al. A unified open-circuit-fault diagnosis method for three-level neutral-point-clamped power converters[J]. IEEE Transactions on power electronics, 2022, 38(3): 3834-3846.

责任编辑: 周建军

(上接第 48 页)

- Sea, China[J]. Marine pollution bulletin, 2018, 137: 509-517.
- [31] 王睿涵. 天津近岸海域海水微塑料分布特征研究[D]. 天津: 天津科技大学, 2019.
- [32] TENG J, ZHAO J M, ZHANG C, et al. A systems analysis of microplastic pollution in Laizhou Bay, China[J]. Science of the total environment, 2020, 745: 140815.
- [33] 陈宏伟, 陈燕珍, 刘宪华, 等. 天津入海排污口微塑料分布特征[J]. 海洋通报, 2020, 39(4): 514-520.
- [34] 李江南, 凌玮, 沈茜, 等. 双台子河与大辽河表层水体微塑料特征与分布研究[J]. 生态毒理学报, 2021, 16(3): 192-199.
- [35] 王旭. 大辽河入海微塑料分布特征、来源及通量研究[D]. 大连: 大连海事大学, 2020.
- [36] 吴楠. 渤海湾近岸微塑料的污染分布特征及其与微生物相互作用研究[D]. 天津: 天津大学, 2019.
- [37] 杨泽川, 胡泓, 王秀海, 等. 莱州湾入海河流的微塑料输入特征研究[J]. 海洋湖沼通报, 2021, 43(5): 73-81.
- [38] ZHANG W W, ZHANG S F, ZHAO Q, et al. Spatio-temporal distribution of plastic and microplastic debris in the surface water of the Bohai Sea, China[J]. Marine pollution bulletin, 2020, 158: 111343.

责任编辑: 周建军