

DOI:10.19651/j.cnki.emt.2108111

基于 IWOA-SVM 的电路软故障诊断*

姜媛媛^{1,2} 牛牧原¹ 陈万利¹

(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) 芜湖 241003)

摘要:针对 DC-DC 电路软故障诊断准确度不高的问题,提出了一种基于改进鲸鱼(IWOA)优化支持向量机(SVM)的电路软故障诊断方法。首先,对故障信号进行 VMD 提取特征向量;然后通过引用反馈机制来改善传统鲸鱼算法的全局搜索能力防止陷入局部最优,把线性因子改为非线性因子用来平衡全局搜索和局部开发能力来改进鲸鱼算法,以解决易陷入局部最优和局部开发能力低的问题。最后建立 IWOA-SVM 模型用来进行电路软故障诊断,最终对电路软故障诊断准确度不高的问题,实现了高效的诊断。根据故障诊断的结果表明,改进后的鲸鱼算法优化支持向量机相比本文对比的其他方法具有更好的诊断效果。故障识别准确率达到 99.1667%。

关键词: DC-DC 电路;软故障诊断;鲸鱼算法;非线性因子;反馈;支持向量机

中图分类号: U226.8+1 **文献标识码:** A **国家标准学科分类代码:** 470.40

Circuit soft fault diagnosis based on IWOA-SVM

Jiang Yuanyuan^{1,2} Niu Muyuan¹ Chen Wanli¹

(1. School of Electrical and Information Engineering, Anhui University of Science & Technology, Huainan 232001, China;

2. Institute of Environment-friendly Materials and Occupational Health, Anhui University of Science & Technology, Wuhu 241003, China)

Abstract: A circuit soft fault diagnosis method based on improved whale (IWOA) optimized support vector machine (SVM) is proposed to address the problem of DC-DC circuit soft fault diagnosis with low accuracy. First, a VMD is performed on the fault signal to extract the feature vectors. Then we improve the global search ability of the traditional whale algorithm to prevent falling into local optimum by referring to the feedback mechanism, and change the linear factor to a nonlinear factor to balance the global search and local exploitation ability to improve the whale algorithm to solve the problem of easily falling into local optimum and low local exploitation ability. Finally, the IWOA-SVM model is used for soft fault diagnosis of circuits, and finally, the problem of low accuracy of soft fault diagnosis of circuits is achieved with high efficiency. Based on the results of fault diagnosis, it is shown that the improved whale algorithm optimized support vector machine has better diagnosis effect compared with other methods compared in this paper. Fault recognition accuracy of 99.1667%.

Keywords: DC-DC circuit; soft fault diagnosis; whale algorithm; nonlinear factor; feedback; support vector machine

0 引 言

电力电子中的 DC-DC 电路已经在航空航天、智能电网、光伏发电等很多的领域里取得了显著进展。DC-DC 电路也变得越来越复杂。目前国内外电路故障诊断研究已经引起了研究者的重视^[1]。电力电子电路的故障模式分为两类:结构故障和参数故障。也就是常说的硬故障和软故障。硬故障又被分为短路和断路故障。硬故障的发生会导致可怕的影响。例如电力电子系统中的突然电压下降或电流上

升,而软故障可能会由于组件磨损或老化而导致系统性能下降。软故障不及时修护会演变成硬故障^[2]。所以,对于一些电子器件的软故障需要进行诊断,以便及时排除故障。整体的方案是先对故障信号进行提取和分析得到特征向量,最后进行故障分类。

在信号的提取和分析过程中,常用的方法是用经验模态分解(EMD)^[3]来处理非线性,非平稳信号。然而 EMD 方法在分解过程中存在过包络,欠包络等问题。针对这个问题,集成经验模态分解算法(EEMD)^[4]可以很好地改善

收稿日期:2021-10-18

* 基金项目:安徽省重点研究与开发计划(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(ALW2020YF18)项目资助

上述问题。但是这个方法和 EMD 都是递归模式分解。无法从根本上解决分解过程中的端点效应和模态混叠问题。而变分模态分解(VMD)^[5]的提出很好的解决了这些问题,并且其分解精度高,收敛速度快。

在分类过程中,支持向量机(SVM)以其很好的分类效果在故障诊断中受到了广泛推广^[6],但其参数设定困难,而参数对分类结果影响较大。于是有专家学者提出算法来优化参数。如张弛^[7]将基于 CNN-SVM 的模型应用于滚动轴承的故障诊断,有效提高了故障特征提取的准确率。如郝爽洁等^[8]将基于混合灰狼算法(HGWO)优化 SVM 在对于燃煤电站锅炉受热面积灰预测方面实现了对省煤器吸热量的实时预测。如周建民等^[9]粒子群算法(PSO)优化 SVM 在电流放大器的故障诊断中更快速有效的对故障分类,有很高的准确率。刘冬梅等^[10]PSO 优化 SVM 在电流放大器的故障诊断中更加快速有效的对故障分类,有很高的准确率。本文在传统鲸鱼算法(WOA)基础上加入了反馈机制和引入非线性因子,通过鲸鱼彼此的反馈,提高了算法的全局搜索能力,跳出局部最优值。加强了其准确度,提高了收敛速度。然后用改进的鲸鱼算法(IWOA)优化 SVM 以提高分类精度。

综上所述,针对电路软故障诊断中的特征提取和分类困难的问题。首先本文在特征提取方面使用了 VMD 分解,得到本征模态分量。然后使用 IWOA-SVM 的模型进行诊断,最后得出诊断结果。该方法经过对比试验的验证,证明了该方法的可行性和有效性。

1 算法的基本原理

1.1 支持向量机与特征向量的提取

支持向量机(SVM)是一种基于统计学习理论的有监督机器学习算法,具有优秀的泛化和低数据要求的回归与分类建模能力,被广泛运用在故障诊断中。本文选用 SVM 是因为 SVM 和其他分类器例如极限学习机(ELM)^[11]相比具有很好的分类效果,它可以寻找一个最优的超平面,使得不同的数据最近分界面与超平面的距离最大。

$$\begin{cases} \min \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n \epsilon_i \\ \text{s. t. } y_i [(\omega x_i) + b] \geq 1 - \epsilon_i; \\ \epsilon_i \geq 0; i = 1, 2, \dots, n \end{cases} \quad (1)$$

式中: ω 为权值向量; x 为训练样本; y_i 为样本的类别; b 是训练样本的阈值; C 是惩罚参数; ϵ_i 是松弛因子。构造拉格朗日函数求解可写做式(2),对式(2)中的 ω 和 b 求偏导为 0。

$$L(\omega, b, \alpha) = \frac{1}{2} \|\omega\|^2 + \sum_{i=1}^m \alpha_i [1 - y_i (\omega^T x_i + b)] \quad (2)$$

得到它的对偶形式为:

$$\begin{cases} \max \left(\sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n y_i y_j \alpha_i \alpha_j x_i^T x_j \right) \\ \text{s. t. } 0 \leq \alpha_i \leq C; i = 1, 2, \dots, n; \sum_{i=1}^n \alpha_i y_i = 0 \end{cases} \quad (3)$$

式中: α_i, α_j 为拉格朗日乘子, $\alpha_i \geq 0, \alpha_j \geq 0; (x_i, y_i)$ 为函数参数。

由上式可得 SVM 需要优化惩罚参数和核函数故采用算法对其优化以提高故障分类的性能。

由于 DC-DC 电路各类故障存在相似性,这对故障信号的特征提取来说较为困难,于是选择 VMD 的故障特征提取方法,VMD 的原理是首先构造变分问题,假设原始信号 f 被分解为 k 个分量,保证分解序列为具有中心频率的有限宽带的模态分量,同时各模态的估计带宽和最小,约束条件是所以模态和与原始信号相等,约束变分表达式为:

$$\begin{cases} \min_{\{u_k, \omega_k\}} \left\{ \sum_k \|\partial_t [(\delta(t) + j/\pi t) \times u_k(t)] e^{-j\omega_k t} \|^2 \right\} \\ \text{s. t. } \sum_k u_k = f \end{cases} \quad (4)$$

式中: ∂_t 是函数对 t 的偏导, $\{u_k\}, \{\omega_k\}$ 分别对应分解后的第 k 个模态分量和中心频率。然后解上式,引入了 Lagrange 乘法算子 λ , 将约束变分问题转变成非约束变分问题,得到的表达式为:

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_k \|\partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) \times u_k(t) \right] e^{-j\omega_k t} \|^2 + \|f(t) - \sum_k u_k(t)\|^2 + \langle \lambda(t), f(t) - \sum_k u_k(t) \rangle \quad (5)$$

式中: α 是二次惩罚因子,用来降低高斯噪声的干扰, $\lambda(t)$ 起到保持约束条件的作用。

1.2 WOA 算法

鲸鱼算法是元启发式优化算法^[12],模拟座头鲸的捕食行为。其捕食行为包括包围猎物、狩猎行为和搜索猎物。本文是以目标函数的最小值为优化目标,适应度值越小的个体越优,越大的越差。本文选用鲸鱼算法是因为和别的算法相比鲸鱼算法的收敛速度很快,用来优化 SVM 的效果也很好。

在包围捕食阶段中,座头鲸要包围猎物,为了描述这种行为,Mirjalili 提出了下面的数学模型:

$$D = |C \cdot X^* - X_t| \quad (6)$$

$$X_{t+1} = X^* - A \times D \quad (7)$$

式中: A, C 表示系数向量; $X^* - X_t$ 表示参考鲸鱼的随机位置向量; X_t 表示当前鲸鱼的位置向量, X_{t+1} 表示鲸鱼接下来要移动的位置向量。系数 A, C 表示如下:

$$A = 2a \cdot r_1 - a \quad (8)$$

$$C = 2 \cdot r_2 \quad (9)$$

$$a(t) = 2 - \frac{2t}{T_{\max}} \quad (10)$$

在式(8)~(10)中 r_1, r_2 是 $[0, 1]$ 中的随机数, a 为控制参数, a 的值从 2~0 线性下降, t 表示当前的迭代次数, T_{\max} 为最大迭代次数。

在狩猎行为中,模仿座头鲸的狩猎行为,它是以螺旋运动游向猎物,鲸鱼以螺旋形状游向猎物的同时还要收缩包围圈。其数学模型为:

$$X(t+1) = \begin{cases} X^*(t) - A \cdot D, & p < 0.5 \\ D \cdot e^{it} \cdot \cos(2\pi t) + X^*(t), & p \geq 0.5 \end{cases} \quad (11)$$

攻击猎物时,在数学模型上设定减小 a 的值,如此 A 的波动范围也随之下降。在迭代过程中 a 的值从 2 降低到 0。 A 是范围 $[-a, a]$ 内的随机值,当 A 在 $[-1, 1]$ 内,鲸鱼的下一个位置就是现在位置和猎物之间的位置。当 $A > 1$ 时,鲸鱼在收缩包围圈外游动。在搜索猎物时,它的数学模型如下:

$$X(t+1) = X_r - A \cdot |C \cdot X_r - X_t| \quad (12)$$

其中, X_r 是随机选择鲸鱼的位置向量,当 $A \geq 1$ 时,进入搜索模式。根据随机鲸鱼位置来更新其他的鲸鱼的位置,这样的话鲸鱼会远离这个猎物去寻找下一个更可口的猎物。以此来寻找最优值。

2 算法的改进

2.1 对攻击猎物阶段的改进

在此阶段中,传统鲸鱼算法(WOA)在种群中随机选取一个个体鲸鱼进行寻优,因为这种随机选取导致随机性比较强,会使得鲸鱼算法(WOA)的稳定性变差,寻优的精度降低。于是,在这个阶段加入了均值向量,使得每个寻优个体通过反馈自身的位置信息取其平均值^[13],这为所有鲸鱼寻找新位置做了向导。避免了多数鲸鱼寻找同一位置的尴尬。避免了随机性造成的误差。其数学公式为:

$$X(t+1) = X(t) + r \cdot (\bar{X} - X(t)) \quad (13)$$

式中: \bar{X} 是所有鲸鱼当前位置 $X(t)$ 的平均向量。

2.2 对包围捕食阶段的改进

在这个阶段中,根据式(10)可以看出,收敛因子 a 是从 2~0 的线性递减的,由于是线性递减的不能很好的控制全局搜索能力,因此选用非线性因子^[14]数学公式如下:

$$a(t) = 2 - 2\sin\left(u \frac{t}{\max_iter} \pi + \varphi\right) \quad (14)$$

式中: \max_iter 是最大迭代次数, u 和 φ 是相关参数,取 $u=2, \varphi=0, t$ 是当前的迭代数。式(10)和(14)对比如图 1 所示。

2.3 对狩猎行为阶段的改进

由于此阶段所有的鲸鱼都向最优鲸鱼位置螺旋靠近,这要保证最优鲸鱼有良好的导向性,不然容易陷入局部最优的结果,针对这个问题,引入了标准差。通过计算最优鲸鱼和均值鲸鱼的标准差,再用正态分布来更新最优鲸鱼^[13]。可以很好地解决这个问题。其数学公式如下:




图 1 线性因子和非线性因子的对比图

$$std = |X^* - X| \quad (15)$$

$$X_{new}^* = randn(X^*, std) \quad (16)$$

式中: X^* 是最优鲸鱼的位置, $randn$ 是正态分布, std 是标准差, X_{new}^* 是新的最优解。

2.4 算法改进的操作流程

对于鲸鱼算法改进的流程如图 2 所示。其实现步骤如下。

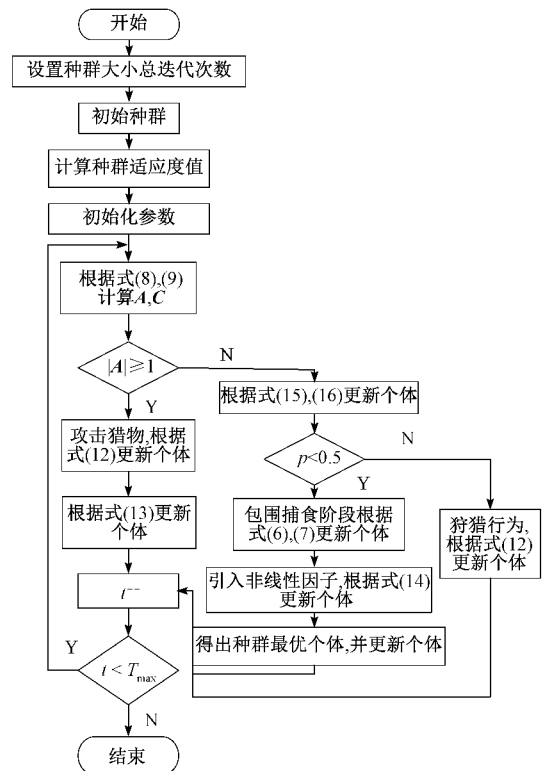


图 2 算法改进流程

1) 初始化鲸鱼参数,如设置其种群规模为 N ,最大迭代次数为 T_{\max} ,初始化的上界 U_b ,下界 L_b 。

2) 根据式(8),(9)计算 A, C 的值。

3) 如果 $A \geq 1$ 则进入攻击猎物阶段,根据式(12)更新个体,基于均值个体的游走觅食反馈,按式(13)更新个体。如果 $A < 1$ 则根据式(15),(16)更新个体。

4) 在 $A < 1$ 的基础上,如果 $p < 0.5$ 则进入包围捕食阶

段,根据式(6),(7)更新个体,同时把线性因子改成非线性因子如式(14)更新个体得到种群最优个体。反之则根据式(12)进入狩猎行为更新个体

5)判断是否满足最大迭代次数要求,若已经满足,则输出结果,否则返回步骤 2)。

3 实验与分析

本文是用 UC3843 芯片控制的 150 W Boost 电路来实验,输入电压是 12 V,输出电压是 24 V,负载是 100 Ω,50 W 的电阻^[15],电路原理如图 3 所示。

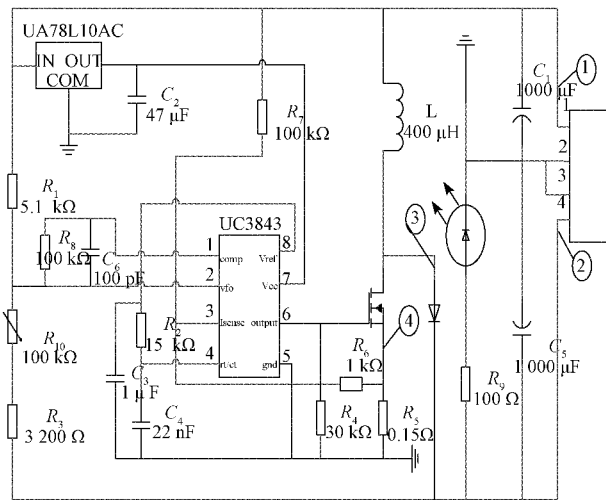


图 3 电路原理

此电路中的电解电容的故障率要保证低于 60%才能正常工作,于是对电解电容 C_1, C_5 进行研究。本文设置了 16 种软故障模式,如表 1 所示。

表 2 不同 K 值 VMD 分解各 IMF 分量的中心频率

分解层数	中心频率/Hz									方差
2	0.000 139	0.243 731								0.029 668 438
3	0.000 126	0.166 862	0.333 641							0.027 808 113
4	0.000 122	0.166 513	0.250 085	0.411 411						0.029 359 243
5	0.000 072	0.083 315	0.167 308	0.333 056	0.416 703					0.029 829 851
6	0.000 069	0.083 199	0.166 795	0.249 761	0.333 522	0.416 745				0.024 316 248
7	0.000 068	0.083 200	0.166 785	0.249 647	0.292 246	0.333 643	0.416 749			0.021 273 135
8	0.000 067	0.083 173	0.166 384	0.167 037	0.249 785	0.333 491	0.417 766	0.416 977	0.023 393 305	

由表 2 可以看出,当 K 值为 2,3 的时候,最后的 IMF 分量未被完全分解,这时还是欠分解状态。当 K 值为 7 和 8 的时候,会发现相邻数据之间有重叠的现象,此时是过分解状态。只有当 K 值为 5 的时候其方差最大,即中心频率最离散。故选择 K 值为 5,并提取每个 IMF 分量的能量熵作为特征向量,则每组数据有 5 个故障特征向量。组合数据构成样本集为 800×20 的数据。

3.2 分类器的选取

本文为了说明 SVM 的优势,使用了 ELM 和 SVM 对

表 1 电容软故障模式

类型	μF		类型	μF	
	C_1	C_5		C_1	C_5
f11	988	916	f31	655	916
f12	988	887	f32	655	887
f13	988	653	f33	655	653
f14	988	554	f34	655	554
f21	864	916	f41	546	916
f22	864	887	f42	546	887
f23	864	653	f43	546	653
f24	864	554	f44	546	554

本文选取了 4 个测试点分别为:1 号测点-输入电压,2 号测点-输出电压,3 号测点-MOS 管漏极电压,4 号测点-MOS 管源极电压。每种电容软故障模式下 4 个测点各采集 50 组数据。其诊断流程如图 4 所示。




图 4 诊断流程

3.1 特征提取

实验采集了 16 种故障信号,每个信号里的数据 2 000 个分为一组,共有 50 组。一共有 800 组数据。把原始数据通过 VMD 分解提取能量熵,本文根据测试不同 K 值下的 IMF 分量的中心频率确定分解层数 K,不同 K 值对应中心频率如表 2 所示。

比进行实验,分别设置训练集和样本集比例 6 : 4,7 : 3,8 : 2 三种对比,其对比图如图 5~7 所示。

在图 5(a)和(b)中都有 $X = 126, X = 180, X = 192, X = 273$ 的点出现错误,可以明显看出 SVM 的诊断率比 ELM 的诊断率高。

在图 6(a)和(b)中都有 $X = 109$ 的点出现错误,SVM 的诊断率比 ELM 高 2.916 7%。

在图 7(a)和(b)中都有 $X = 45$ 的点错误,很明显和 SVM 相比 ELM 的错误点更多,诊断率更低。

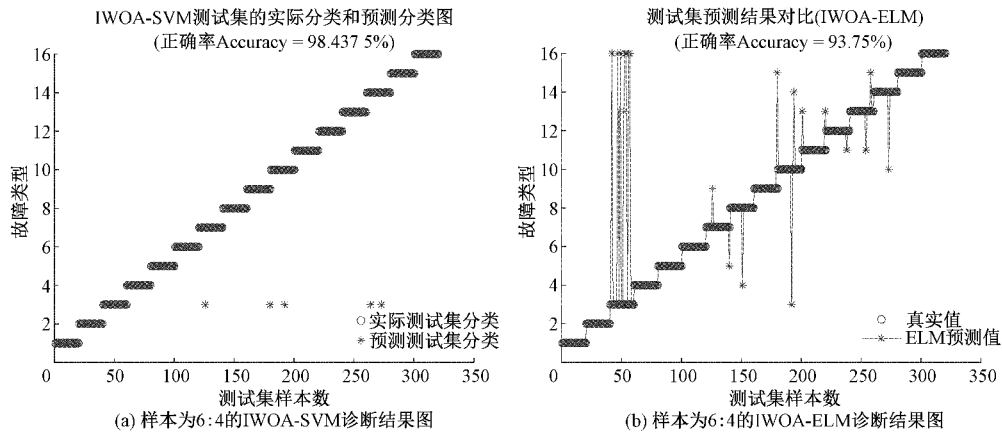


图 5 样本为 6 : 4 的 IWOA-SVM 和 IWOA-ELM 的诊断模型对比图




图 6 样本为 7 : 3 的 IWOA-SVM 和 IWOA-ELM 的诊断模型对比图

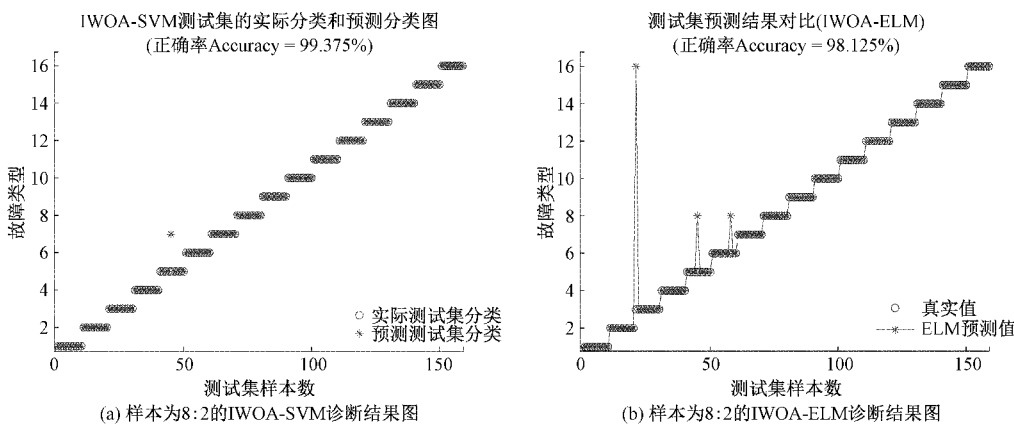


图 7 样本为 8 : 2 的 IWOA-SVM 和 IWOA-ELM 的诊断模型对比图

3.3 算法收敛性对比

本文使用了 WOA-SVM^[16], HHO-SVM^[17], LSO-SVM^[18], SSA-SVM^[19] 和 IWOA-SVM 分别对故障信号进行分类。其中 IWOA-SVM 的参数设置为最大迭代次数为 100, 种群数量为 30。这 5 种算法的迭代曲线如图 8 所示。

由图 8 可知,改进鲸鱼优化的 SVM,在第 3 代跳出局

部最优,第 4 代达到准确最优解,其错误率最低为 0.008 333,传统 WOA 的方法易陷入局部最优,其错误率为 0.020 83,SSA 的方法第 10 代收敛,收敛速度和 IWOA 相比较慢,其错误率为 0.016 67,HHO 算法第 24 代收敛,其错误率为 0.037 5。由此可以说明 IWOA 模型比 WOA, HHO, SSA, LSO 的模型拥有更快的收敛速度和更高的精度。

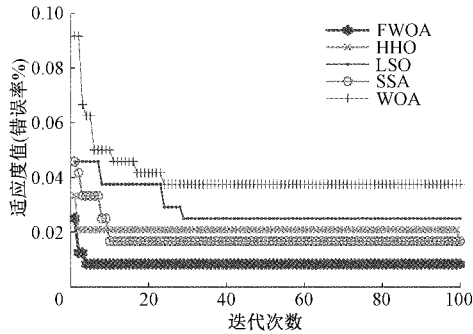


图 8 迭代曲线对比图

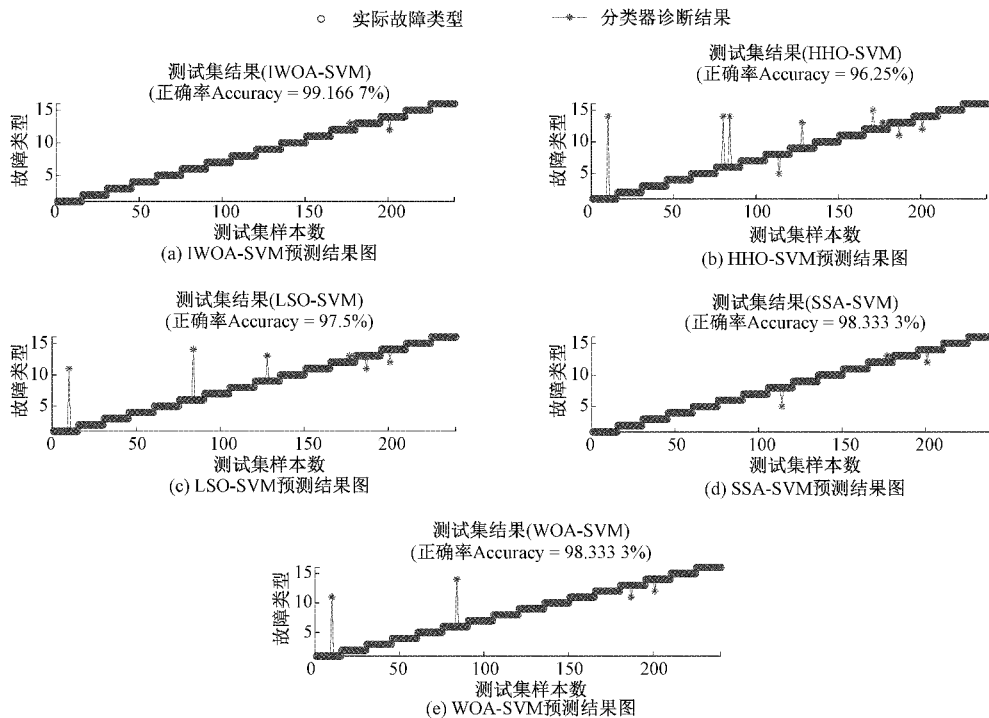


图 9 各类模型故障预测结果对比图

表 3 诊断结果参数表

模型	IWAO-SVM	HHO-SVM	LSO-SVM	SSA-SVM	WOA-SVM
正确率/%	99.166	96.25	97.5	98.333	98.333
运行时间(t)	90.063	118.70	90.526	142.319	87.922

运行时间相对较短。收敛速度最快。虽然 WOA-SVM 模型的运行时间最短,但是诊断率没有 IWOA-SVM 模型高。由此说明,本文提出的故障诊断方法要优于其他 4 种方法。基于 IWOA-SVM 的电路软故障诊断方法是可行且有效的。IWOA-SVM 可以提高电路软故障诊断的准确率。

4 结 论

针对电路软故障诊断准确度不高的问题,提出了一种基于 IWOA-SVM 的故障诊断方法用于电路软故障诊断。通过对 DC-DC 电路实验数据的故障诊断,验证了该方法

3.4 基于 IWOA-SVM 的诊断模型

实验是将 800×20 组数据中的 560×20 组数据作为训练数据剩下的 240×20 组数据作为测试数据。将特征向量信号导入本文提出的改进鲸鱼算法(IWOA)优化的支持向量机(SVM)得到的诊断结果和其他几种模型对比如图 9 所示。

表 3 所示为 5 种模型的诊断结果。由表 3 和图 9 可知,IWOA-SVM 模型的诊断结果达到了 99.166%,比 WOA-SVM,HHO-SVM,SSA-SVM,LSO-SVM 分别提高了 0.833%,2.916%,0.833%,1.666%。而且 IWOA-SVM 的

分类器诊断结果

的可行性和准确性,结论如下:使用 VMD 提取故障信号生成特征向量,使得对故障诊断的更加全面。将反馈机制引入到鲸鱼算法中,同时把非线性因子改为非线性因子。改进后的算法具有更强的寻优能力,和支持向量机相结合的 IWOA-SVM 模型比 WOA-SVM 模型,LSO-SVM 模型,HHO-SVM 模型和 SSA-SVM 模型有更好的诊断效果。利用提出的 IWOA-SVM 的诊断方法可以更加快速和准确的发现 DC-DC 电路的软故障,从而预防了硬故障的产生。减少了检修时间,具有一定的可行性和实用价值。同时,本文的诊断模型虽然效果好但是诊断时间还有待提高,下

一步的内容就是能快速的诊断出故障类型,以便能快速的找出故障。同时,本文算法也为其他领域的故障诊断提供了一种新的研究方向。

参考文献

- [1] 张朝龙,何怡刚,杜博伦.基于 DBN 特征提取的模拟电路早期故障诊断方法[J].仪器仪表学报,2019,40(10):112-119.
- [2] SUN Q, WANG Y, JIANG Y. A novel fault diagnostic approach for DC-DC converters based on CSA-DBN[J]. IEEE Journals & Magazines, 2018, 6: 6273-6285.
- [3] 吴虎,孔勇,王振伟,等.基于 EMD 分解与 1-D CNN 算法的光纤振动信号的识别[J].激光与红外,2021,51(8):1043-1049.
- [4] 陆丹,肖志怀,刘东,等.基于 EEMD-GA-BP 的水电机组状态趋势预测[J].中国农村水利水电,2021(8):186-194.
- [5] 卿宗胜,高云鹏,吴聪,等.基于自适应 VMD 和改进功率谱估计的球磨机负荷特征提取[J].仪器仪表学报,2020,41(5):234-241.
- [6] 尹金良,朱永利.支持向量机参数优化及其在变压器故障诊断中的应用[J].电测与仪表,2012,49(5):11-16.
- [7] 张弛.基于 CNN-SVM 的滚动轴承故障诊断[J].组合机床与自动化加工技术,2021(11):114-116,124.
- [8] 郝爽洁,陈超波,王景成,等.基于 HGWO-SVM 的燃煤电站锅炉受热面积灰预测[J].国外电子测量技术,2020,39(10):1-5.
- [9] 周建民,李家辉,尹文豪,等.基于 CEEMDAN 和 PSO-OCSVM 的滚动轴承性能退化评估[J].电子测量与仪器学报,2021,35(7):194-201.
- [10] 刘冬梅,霍龙龙,王浩然,等.基于 PSO-SVM 的电流放大器故障诊断研究[J].传感器与微系统,2021,40(8):50-52,56.
- [11] 赵沁峰,蔡艳平,王新军.基于 WOA-ELM 的锂离子电池剩余寿命间接预测[J].中国测试,2021,47(9):138-145.
- [12] 葛红平,刘晓波,黄朝晖,等.粒化幅值感知排列熵和 WOA-SVM 的滚动轴承故障诊断[J].噪声与振动控制,2021,41(4):101-108,160.
- [13] 范家承,何杰光.基于反馈机制的鲸鱼优化算法[J].广东石油化工学院学报,2018,28(4):47-51.
- [14] 武泽权,牟永敏.一种改进的鲸鱼优化算法[J].计算机应用研究,2020,37(12):3618-3621.
- [15] 姜媛媛,陈李,魏念巍.基于时域特征 DC-DC 电路软故障诊断[J].新余学院学报,2020,25(2):11-18.
- [16] 湛健.基于 WOA-SVM 响应面法的大坝可靠度分析[D].长沙:长沙理工大学,2019.
- [17] 朱楚昱,李川,李英娜.基于特征优选和 HHO-SVM 的变压器故障识别[J].电视技术,2021,45(2):60-66.
- [18] 丁飞,江铭炎.基于改进狮群算法和 BP 神经网络模型的房价预测[J].山东大学学报(工学版),2021,51(4):8-16.
- [19] 胡鸿志,覃畅,管芳,等.基于麻雀搜索算法优化支持向量机的刀具磨损识别[J].科学技术与工程,2021,21(25):10755-10761.

作者简介

姜媛媛,博士研究生,教授,主要研究方向为电力电子系统故障诊断与预测。

E-mail:jyyl672@163.com

牛牧原,硕士研究生,主要研究方向为电力电子系统故障诊断与预测。

E-mail:1875358630@qq.com