

DOI: 10.13382/j.jemi.B2104972

联合 VMD 与 ISSA-ELM 的电力电子电路软故障诊断^{*}

朱文昌^{1,2} 李振璧³ 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)
 芜湖 241003; 3. 亳州学院电子与电气工程系 亳州 236800)

摘 要:针对电力电子电路的软故障特征区分度差、不易诊断等问题,提出了变分模态分解(VMD)结合改进的麻雀搜索算法(ISSA)优化极限学习机(ELM)的故障诊断方法。首先,将采集的故障信号进行VMD分解成本征模态分量(IMF),提取线性重构后IMF的12维时域参数作为故障诊断的特征向量。其次为提高ELM在故障诊断中的精度,提出ISSA对ELM的参数进行优化,建立ISSA-ELM分类模型。ISSA首先采用Iterative映射初始化种群,然后在发现者位置更新处引入自适应惯性权重因子,最后在解的位置引入Levy变异算子进行扰动得到新解等3种策略改进,提高算法性能。在8类基准函数测试中,ISSA比另外4种智能算法的收敛速度和寻优精度均有提升,并且VMD结合ISSA-ELM在功率为150W Boost电路软故障诊断中精度达到99%以上。

关键词:变分模态分解;极限学习机;改进麻雀搜索算法;电路软故障诊断

中图分类号: U226.8⁺1; TN108.7 **文献标识码:** A **国家标准学科分类代码:** 470.4

Combined VMD and ISSA-ELM for soft fault diagnosis of power electronic circuits

Zhu Wenchang^{1,2} Li Zhenbi³ Jiang Yuanyuan^{1,2}
(1. School 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; 3. Department of Electronics and Information Engineering, Bozhou University, Bozhou 236800, China)

Abstract: To address the problems of poor differentiation of soft fault features of power electronic circuits and not easy to diagnose, a fault diagnosis method of variational modal decomposition (VMD) combined with an improved sparrow search algorithm (ISSA) optimized extreme learning machine (ELM) is proposed. Firstly, the acquired fault signals are decomposed into the intrinsic modal components (IMF) by VMD, and the twelve-dimensional time-domain parameters of the linearly reconstructed IMF are extracted as the feature vectors for fault diagnosis. Secondly, in order to improve the accuracy of ELM in fault diagnosis, ISSA is proposed to optimize the parameters of ELM and establish ISSA-ELM classification model. ISSA is improved by three strategies such as initializing the population with Iterative mapping, introducing adaptive inertia weight factor at the discoverer position update, and introducing levy variation operator to perturb at the solution position to get a new solution to improve the algorithm performance. In the 8-class benchmark function test, ISSA has improved the convergence speed and finding accuracy than the other 4 intelligent algorithms, and the accuracy of VMD combined with ISSA-ELM reaches more than 99% in the soft fault diagnosis of 150 W Boost circuit.

Keywords: variational modal decomposition; extreme learning machine; improved sparrow search algorithm; circuit soft fault diagnosis

0 引言

电力电子电路作为电气设备中常见的器件,其稳定运行以及故障的及时诊断和排除意义十分重大。目前,对故障诊断已有多种方法^[1-3],但绝大多数都是针对电路结构性硬故障进行诊断;对于电力器件参数衰退的软故障,其具有缓变性,虽然不会突然造成电路功能的丧失,但若没及时发现处理,会演变成硬故障并造成重大影响。及时排除软故障具有重大意义,但因其特征区分度差,不易诊断,现有研究较少^[4]。

电力电子电路故障诊断主要包括故障特征提取和故障分类两大关键技术。故障特征提取方面,文献[5]采用离散小波(discrete wavelet transformation, DWT)对信号进行处理,但小波分解中阈值和小波基的选取对特征提取影响较大且尚无统一标准;经验模态分解(empirical mode decomposition, EMD)处理非平稳信号时能显著突出信号局部特征且无需选择基函数^[6],但其端点效应和模态混叠同样影响特征提取的效果。变分模态分解(variational modal decomposition, VMD)特点在于将信号分解问题转变为变分问题,克服了模态混叠及端点效应问题^[7-8],实现了本征模态分量(intrinsic mode function, IMF)有效分解,并将机械故障诊断研究中常用的时域参数引入,有量纲系数在反应信号曲线特征方面有明显优势,无量纲系数具有稳定性和抗干扰能力,两者的兼顾选择可以有效反应信号特征。将 IMF 小波降噪处理后,再提取重构的 IMF 的时域参数,作为故障信号的特征向量。

近年来,人工神经网络在故障诊断领域已广泛运用,其中常用的是 BP(back propagation)和朴素贝叶斯(naive Bayes, NB)分类模型;虽然 BP 精度高,但学习速度慢,参数设置多限制了 BP 在故障诊断中的应用^[9];NB 高效且适合多分类问题,但是对输入数据的形式很敏感。极限学习机(extreme learning machine, ELM)是一种单隐层前馈神经网络,其学习速度快,泛化能力强^[10],适合在故障诊断中应用,但由于 ELM 的权值和阈值随机设定,会影响故障诊断的稳定性和准确性。文献[11-12]分别采用改进的鲸鱼优化算法和改进的烟花算法对 ELM 的参数进行优化,有效的提高了 ELM 分类的稳定性和准确性,为优化 ELM 性能提供了新思路。

以粒子群算法为代表的群智能算法在人工智能高速发展的背景下兴起,粒子群算法模仿鸟群觅食机制,通过迭代计算得到个体极值的最优解,具有较好的通用性,并有效解决了工程应用等复杂问题。经过众多学者的研究,优秀群智能算法被不断提出,如飞蛾扑火优化算法(moth-flame optimization algorithm, MFO)、鲸鱼优化算法(whale optimization algorithm)、哈里斯鹰优化算法(Harris

hawks optimization, HHO)和人工鱼群算法等。本文采用的麻雀搜索算法(sparrow search algorithm, SSA)是 2020 年 Xue 等^[13]提出的一种新型的群智能算法,该算法比较新颖,具有寻优能力强,收敛速度快等优点。然而在算法迭代后期,不可避免同其他智能算法一样容易出现陷入局部最优的问题。文献[14-15]提出了多种策略,克服了 SSA 的部分不足。本文利用混沌性较好的 Iterative 映射初始化种群,使种群具有更好的空间解分布;在发现者位置更新方式引入上一代全局最优和自适应权值来兼顾全局和局部搜索,加快收敛速度;利用轮盘赌选择 Levy 变异的麻雀,增强了算法跳出局部最优的能力,最后用贪心规则确保得到最优值。

基于此,本文首先采用 VMD 将故障信号进行分解,将 IMF 小波降噪后,提取重构的 IMF 的 12 维时域参数,得到故障信号的特征向量。然后通过 3 种改进策略对 SSA 进行优化,并在 8 类基准函数上进行测试后表明改进后的 SSA 的收敛速度、精度和跳出局部最优的能力比原始的 SSA 以及 MFO、WOA、HHO 均更好。最后通过 ISSA 对 ELM 网络参数进行优化,得到 ISSA-ELM 分类模型。在功率为 150 W 的 Boost 电路软故障诊断实验表明,所提方法在电路软故障诊断方面的准确率有很大提高。

1 特征提取

1.1 VMD

VMD 是一种自适应、完全非递归的模态变分和信号处理的方法,VMD 核心思想是将变分求解问题来替代信号的分析,该方法将序列分解为 K 个 IMF,并且匹配每种 IMF 的最优中心频率和有限带宽,能够有效的避免产生模态混叠的现象^[16]。VMD 在故障特征提取和表征原始信号的能力上有着显著的优越性,并在机械领域故障诊断中已经广泛应用。

1.2 VMD 结合时域参数

电力电子电路故障诊断中,一般选取易测量的电压信号作为原始故障信号,通常是用 VMD 将获取的电压信号分解成多层 IMF,并提取每层 IMF 的样本熵,信息熵等作为电路故障的特征向量,如文献[17]也取得了较好的效果。而时域参数在机械故障诊断中已广泛运用,但在电路故障诊断中研究较少。根据 DC-DC 电路软故障信号微弱,噪声影响大,不同类别的软故障直接存在重叠等特性,本文选用表 1 的时域参数,作为 DC-DC 电路的故障特征参数,其中 q_1 - q_6 为有量纲参数,在信号曲线特征方面有明显优势,但抗干扰能力弱, q_7 - q_{12} 为无量纲参数,具有一定的抗干扰能力,有量纲参数和无量纲参数的同

时采用,可以提高故障辨识的准确性。表 1 中 12 维时域参数的选用可保证对不同类型软故障的特点和敏感性的兼顾。其中 $Q(i)$ 为时域信号序列, $i=1,2,\cdots,N$ 为采样点数。

当故障信号经 VMD 分解为多个 IMF 后,含有故障特

征最多的 IMF 只有 1~2 个,其余 IMF 含噪声较多^[18]。因此采用小波降噪后,将每层 IMF 线性叠加重构,形成一个新的波形,再提取波形的时域参数,作为故障诊断的特征向量。

表 1 时域参数及计算公式

Table 1 Time domain parameters and calculation formula

时域参数	计算公式	时域参数	计算公式
均值	$q_1 = \frac{1}{N} \sum_{i=1}^n Q(i)$	偏斜度	$q_7 = \frac{1}{N} \sum_{i=1}^n (Q(i) - q_1)^3$
标准差	$q_2 = \sqrt{\frac{1}{N} \sum_{i=1}^n (Q(i) - q_1)^2}$	峰值指标	$q_8 = \frac{q_5}{q_4}$
方根幅值	$q_3 = (\frac{1}{N} \sum_{i=1}^n (\sqrt{ Q(i) }))^2$	波形指标	$q_9 = \frac{q_4}{ q_1 }$
均方根值	$q_4 = \sqrt{\frac{1}{N} \sum_{i=1}^n Q^2(i)}$	裕度指标	$q_{10} = \frac{q_5}{q_3}$
峰值	$q_5 = \max Q(i) $	峭度指标	$q_{11} = \frac{1}{N} \sum_{i=1}^n (Q(i) - q_1)^4$
峰峰值	$q_6 = \max(Q(i)) - \min(Q(i))$	脉冲指标	$q_{12} = \frac{q_7}{ q_1 }$

2 麻雀搜索算法及改进

2.1 传统的麻雀搜索算法

SSA 是对麻雀在觅食过程和反捕食行为的模拟,种群分为发现者、跟随者、警报者 3 个部分。发现者适应度较高,在种群中负责寻找食物并为整个麻雀种群提供觅食区域和方向,而跟随者则是跟随发现者获取食物,以得到更高的适应度值。此外,当麻雀种群意识到危险时警报者会做出反捕食行为。在每次迭代的过程中,发现者的位置更新公式为:

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t \cdot \exp\left(-\frac{i}{\alpha \cdot T_{\max}}\right), R2 < ST \\ X_{i,j}^t + Q \cdot L, R2 \geq ST \end{cases} \quad (1)$$

式中: t 表示当前迭代次数, $X_{i,j}$ 表示第 i 个麻雀种群在第 j 维中的位置信息, α 表示 0~1 的随机数, T_{\max} 表示最大迭代次数, Q 表示一个服从正态分布的随机数, L 是一个 $1 \times D$ 并且元素全为 1 的矩阵, $R2 \in (0,1]$ 表示预警值。

跟随者的位置更新公式为:

$$X_{i,j}^{t+1} = \begin{cases} Q \cdot \exp\left(\frac{X_{\text{worst}} - X_{i,j}^t}{i^2}\right), i > n/2 \\ X_p^{t+1} + |X_{i,j} - X_p^{t+1}| \cdot A^+ + L, i \leq n/2 \end{cases} \quad (2)$$

式中: X_p^{t+1} 表示目前发现者的最优位置, X_{worst} 表示当前全

局最差的位置, A 表示其元素随机赋值为 1 或 -1 的 $1 \times D$ 的矩阵且 $A^+ = A^T(AA^T)^{-1}$ 。

在麻雀种群中,意识到危险的麻雀数量占麻雀总数的 10%~20%,被称为警报者,其位置是随机产生的。

警报者位置更新公式为:

$$X_{i,j}^{t+1} = \begin{cases} X_b^t + \beta |X_{i,j}^t - X_b^t|, f_i > f_g \\ X_{i,j}^t + M \left(\frac{|X_{i,j}^t - X_d^t|}{(f_i - f_w) + \varepsilon} \right), f_i = f_g \end{cases} \quad (3)$$

式中: X_b^t 表示当前全局最优位置, M 是服从标准正态分布的随机数用来作为步长控制参数, β 是一个属于 -1~1 的随机数, f_i 表示当前麻雀个体的适应度值, f_g 表示全局最佳适应度值, f_w 表示全局最差适应度值。

2.2 改进的麻雀搜索算法

目前,SSA 由于其寻优能力强,收敛速度快等优点,在实际问题中应用广泛。但不可避免的与其他智能优化算法一样,有易陷入局部最优以及收敛精度不足的缺点。因此,本文对 SSA 进行了深入研究,提出了 3 种策略进行改进,以提升 SSA 的性能。

1) Iterative 混沌映射初始化种群

对于种群迭代的智能算法,初始种群的质量对算法最终收敛精度有一定的影响。由于混沌映射具有随机性,遍历性等特点,故在改进群算法中常用混沌映射来初始化种群以提高初始种群的质量。其中 tent 模型和

logistic 模型最为常见,但这两类均为映射折叠次数有限的混沌模型,毛清华等^[19]引入映射折叠次数无限的混沌模型进行种群初始化取得了较好效果。本文基于映射折叠次数无限的 Iterative 混沌对 SSA 进行种群初始化。Iterative 混沌一维自映射如式(4)所示。

$$x_{n+1} = \sin \frac{a\pi}{x_n}, n = 0, 1, \dots, N \quad (4)$$

其中, a 为控制参数,一般取 0.7,并为满足在 $[-1, 1]$ 中发生混沌,初始的迭代值 x 不能为 0。设定迭代 1 000 代,Iterative 混沌一维自适应映射的随机性和遍历性与迭代次数的关系如图 1 和 2 所示,发现当迭代到一定代数时,系统将遍布整个解区间。




图 1 Iterative 映射的随机性与迭代次数关系

Fig. 1 Relationship between randomness and iteration times of Iterative mapping




图 2 Iterative 映射的遍历性与迭代次数关系

Fig. 2 Relationship between ergodicity and iteration times of Iterative mapping

2) 惯性权重因子

在 SSA 中,当 $ST < R2$ 时,发现者分布从迭代开始的 $[0, 1]$ 变为 $[0, 0.4]$,如图 3 所示,每一维度都在降低搜索空间,容易陷入局部最优,造成精度不足。为了进一步平衡 SSA 的全局搜索与局部搜索能力,本文引入自适应惯性权重因子^[20],其最大迭代次数和当前迭代次数相关,在迭代前期具有较大的值,满足 SSA 前期需要较强的全局搜索能力,并且迭代后期自适应减小,能更好进行局部搜索,平衡了搜索速度和精度。自适应惯性因子如式

(5) 所示。

$$w = \sin\left(\frac{\pi t}{2T_{\max}} + \pi\right) + 1 \quad (5)$$

其中, t 为当前迭代次数, T_{\max} 为最大迭代次数。

本文对发现者位置更新引入惯性权重因子,另外引入上一代最优的麻雀位置,可以有效扩大解空间,避免陷入局部最优。改进发现者位置更新如式(6)所示。

$$X_{i,j}^{t+1} = \begin{cases} wX_{i,j} + (X_{best} - X_{i,j}) \cdot rand, R2 < ST \\ X_{i,j} + Q \cdot L, R2 \geq ST \end{cases} \quad (6)$$




图 3 原发现者的搜索空间

Fig. 3 Search space of original discoverer

3) Levy 变异

Levy 飞行是一种生成随机步长的方法,可以加强种群信息交互,避免算法陷入局部最优,故在智能算法改进中广泛运用。Levy 飞行服从 Levy 分布,对其简化和傅里叶变化后,可获得幂次函数的形式如式(7)所示。

$$Levy \sim u = t^{-\lambda}, 1 < \lambda \leq 3 \quad (7)$$

Levy 分布十分复杂,通常用 Mantegna 方法模拟,计算如式(8)所示。其中,参数 γ 的取值范围为 $0 < \gamma < 2$,通常取值为 1.5, u, v 为服从式(9)的正态分布随机数,式(8)所对应的正态分布标准差 σ_u, σ_v 的取值满足式(10),式(10)中 Γ 为标准的 Gamma 函数积分运算。

$$s = \frac{u}{|v|^{1/\gamma}} \quad (8)$$

$$\begin{cases} u \sim N(0, \sigma_u^2) \\ v \sim N(0, \sigma_v^2) \end{cases} \quad (9)$$

$$\sigma_u = \begin{cases} \sigma_u = \left\{ \frac{\Gamma(1 + \gamma) \sin(\pi\gamma/2)}{\gamma \cdot \Gamma[(\gamma + 1)/2] \cdot 2^{(\gamma+1)/2}} \right\}^{1/\gamma} \\ \sigma_v = 1 \end{cases} \quad (10)$$

在麻雀种群中,引入 Levy 变异算子在解的位置进行扰动得到新解,对于是否进行 Levy 变异由选择概率 P 决定,如式(11)所示。

$$P = 1 - 1/T_{\max} \quad (11)$$

如果 $rand > P$,则对个体进行 Levy 变异,进行目标位置更新。其中, $rand$ 为 0~1 之间的随机数。

通过 Levy 变异的策略增强了算法跃出局部最优的能力,但要判断经过变异后的新位置是否优于原先位置,本文加入贪心规则,比较两个位置的适应度值,如若更优,进行替换,更新位置。可以促使算法向目标方向进行优化,使算法获得更好的收敛速度和精度。

综上所述,改进的麻雀搜索算法的具体步骤如下:
步骤(1)初始化麻雀参数,如设置麻雀种群规模为 N ,发现者个数 PN ,预警者个数 SN ,目标函数维度 D ,初始值的上界 Ub ,下界 Lb ,最大迭代次数为 T_{\max} 。

步骤(2)用式(4) Iterative 混沌映射对种群进行初始化。

步骤(3)计算出在 D 维空间内,每只麻雀的位置 X_i 和每只麻雀的适应度 f_i 。

步骤(4)对麻雀种群的适应度进行计算后排序,并引入自适应惯性权重,选取每代种群中适应度最好的 PN 只麻雀作为发现者按照式(6)更新,其余 $N-PN$ 只麻雀作为跟随者,按照式(2)更新位置。并选择 SN 数量的个体作为警报者,按照式(3)更新位置。

步骤(5)变异操作,设定自适应概率 P ,if $rand>P$,则对个体进行 Levy 变异,产生新解,并依据贪心规则,确定位置是否更新。

步骤(6)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(3)。

2.3 算法性能测试

为验证 ISSA 的寻优能力和求解精度,选择 8 类基准函数(维度 $d=30$)对算法性能进行检验,基准测试函数的信息如表 2 所示,其中 F1、F2、F3、F4 为单峰函数,可以验证算法的收敛性能,F5、F6、F7、F8 为多峰函数,可以验证算法局部搜索能力和寻优精度。

表 2 基准测试函数
Table 2 Benchmark function

函数	类型	取值范围	最优解
F1	Sphere	$[-100,100]$	0
F2	Schwefel' 2. 22	$[-10,10]$	0
F3	Rosenbork's	$[-100,100]$	0
F4	Quartic	$[-1.28,1.28]$	0
F5	Rastrigin	$[-5.12,5.12]$	0
F6	Ackley	$[-32,32]$	0
F7	Griewank	$[-600,600]$	0
F8	Penalized	$[-50,50]$	0

为了能客观验证改进算法的有效性,与 4 种优化算法进行对比,包括 MFO、WOA、HHO、SSA。实验环境为 MATLAB R2018b,Win10(64 bit),PC 处理器为 Intel(R) Core(TM) i7-9750 H。所有优化算法的种群规模为 30,最大迭代次数为 500,评判标准为每种算法在相同条件下运行 30 次后,取其平均适应度值 mean 和标准差值 std。

5 种群算法优化 8 类基准测试函数的结果如表 3 所示,表中粗体标出的为最优结果,可以看出对于单峰函数 F1~F4 和高维函数 F5~F8,改进后的 SSA 多次寻优的平均值相比于原始 SSA 和其余 3 种算法,均更接近于基准函数的理论最优解,并且标准差也最小,甚至在函数 F1、F2、F5、F7 已经达到理论最优解,证明了 ISSA 相比于其他 4 种群智能算法的求解精度更高、稳定性能更强。

表 3 不同算法的测试结果
Table 3 Test results of different algorithms

函数	算法	平均值	标准差
F1	WFO	2.958×10^0	1.262×10^0
	WOA	1.868×10^{-75}	5.275×10^{-75}
	HHO	3.504×10^{-79}	9.911×10^{-79}
	SSA	1.535×10^{-107}	4.343×10^{-107}
	ISSA	0	0
F2	WFO	2.506×10^1	1.367×10^1
	WOA	2.886×10^{-51}	5.798×10^{-51}
	HHO	3.489×10^{-54}	7.845×10^{-54}
	SSA	1.428×10^{-63}	4.284×10^{-63}
	ISSA	0	0
F3	WFO	2.014×10^3	3.994×10^3
	WOA	4.353×10^{-1}	2.443×10^{-1}
	HHO	2.769×10^{-5}	2.922×10^{-5}
	SSA	1.744×10^{-2}	7.455×10^{-3}
	ISSA	7.543×10^{-10}	1.326×10^{-9}
F4	WFO	8.262×10^0	9.324×10^0
	WOA	2.215×10^{-3}	2.062×10^{-3}
	HHO	2.176×10^{-4}	1.631×10^{-4}
	SSA	9.842×10^{-4}	8.307×10^{-4}
	ISSA	2.973×10^{-5}	2.214×10^{-5}
F5	WFO	1.700×10^3	2.899×10^1
	WOA	0	0
	HHO	0	0
	SSA	0	0
	ISSA	0	0
F6	WFO	1.284×10^1	7.989×10^0
	WOA	3.730×10^{-15}	2.658×10^{-15}
	HHO	8.882×10^{-16}	0
	SSA	8.882×10^{-16}	0
	ISSA	8.882×10^{-16}	0
F7	WFO	1.873×10^0	2.724×10^0
	WOA	0	0
	HHO	0	0
	SSA	0	0
	ISSA	0	0
F8	WFO	1.326×10^3	2.809×10^3
	WOA	4.105×10^{-1}	2.178×10^{-1}
	HHO	8.989×10^{-5}	9.739×10^{-5}
	SSA	2.821×10^{-1}	1.561×10^{-1}
	ISSA	1.296×10^{-7}	1.743×10^{-7}

部分基准函数的迭代收敛曲线如图 4 所示,可以直观的看出算法的收敛速度和跳出局部最优的能力。从函

数 F1、F2、F3 的曲线可以看出,ISSA 比其他 4 种算法收敛精度更高,更接近函数的最优解。由函数 F5、F6、F7 的曲线可以看出,当几种算法收敛精度相同时,ISSA 所需

迭代次数最少,表明 ISSA 一定程度上克服了群算法的缺点。相比于 SSA 和其他 3 种群智能算法,ISSA 的收敛速度更快,精度更高,性能更好。

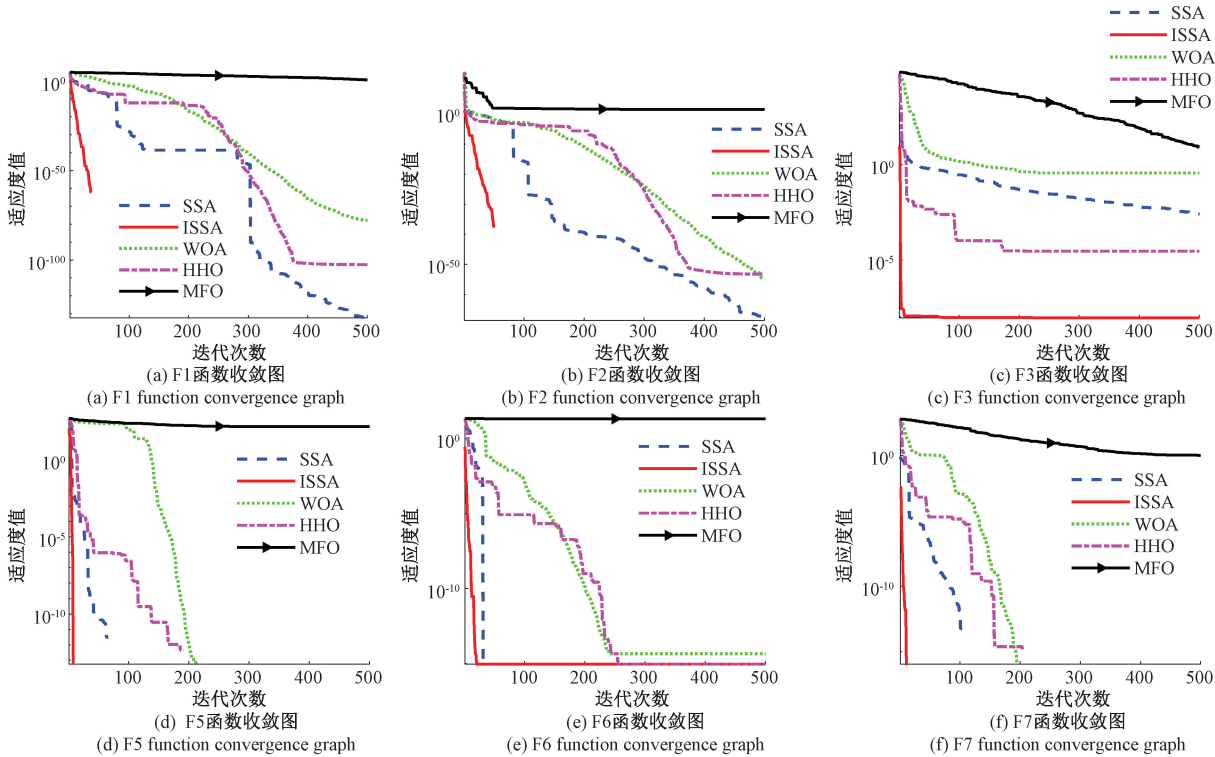


图 4 5 种算法对基准函数的收敛曲线

Fig. 4 Convergence curves of five algorithms on benchmark function

3 ISSA 算法优化极限学习机

3.1 极限学习机

极限学习机是典型的单隐含层前馈神经网络结构,他最大特点是输入层和隐含层的连接权值、隐含层的阈值可以随机设定,且设定完后不用再调整。ELM 具有快速的收敛速度和学习能力,同时有很好的非线性分类能力,在故障诊断中得到了较高的关注。其结构如图 5 所示。




图 5 极限学习机结构图

Fig. 5 Structure diagram of limit learning machine

$$z_i = w^T g(Wa_i + b), i = 1, 2, \dots, N_s \tag{12}$$

式(12)为 ELM 的数学表达式,其中 W 为输入权值, b 为隐含层偏差值, w 为输出权值, a_i 为 q 维输入向量, z_i 为 s 维输出向量, N_s 为样本数, g 为激活函数,通常取 Sigmoid 函数。

选取激活函数,设定隐含层节点 M 后,ELM 网络的学习步骤如下:

- 1) 初始化并随机设定输入权值 W 和隐含层偏差值 $b_i, i = 1, 2, \dots, M$;
- 2) 计算隐含层输出矩阵 H ;
- 3) 计算输出权值 $w, w = H^+ T$ 。

3.2 ISSA-ELM 故障诊断模型建立

针对 ELM 随机设定参数对故障诊断结果有较大影响,本文通过 ISSA 优化 ELM 设定的权值和阈值,建立 ISSA-ELM 模型,提高故障诊断的准确率。流程如图 6 所示。

4 DC-DC 电路软故障特征参数分析

4.1 电路结构与软故障模式设置

本文以 UC3843 芯片控制的功率为 150 W Boost 电

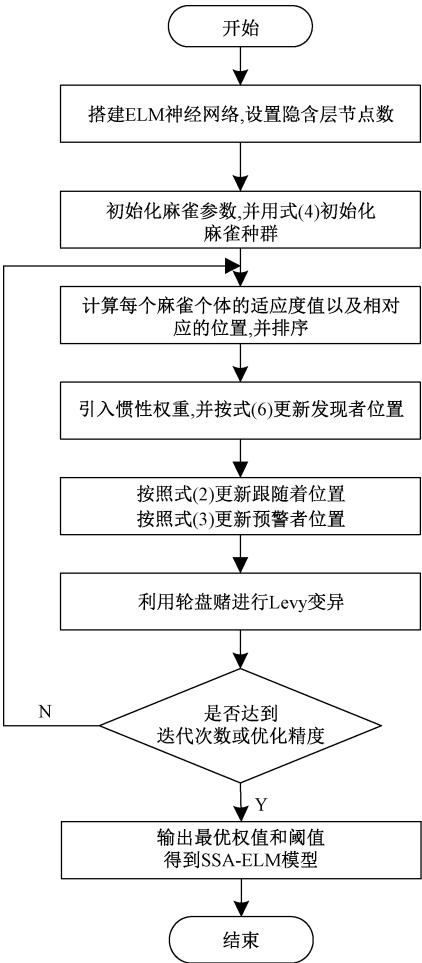


图 6 ISSA 优化 ELM 流程

Fig. 6 ISSA optimized ELM flow chart

路为例验证所提方法,该电路输入电压为 12 V,输出电压为 24 V,负载为 100 Ω,电阻功率为 50 W, C_1 和 C_5 的标准值为 1 000 μf,实物图、参数失效实验平台、电路原理图分别如图 7、8、9 所示。




图 7 实物图

Fig. 7 Physical picture




图 8 参数失效实验平台

Fig. 8 Parametric failure experimental platform

在 DC-DC 电路中,电解电容的平均故障率高达

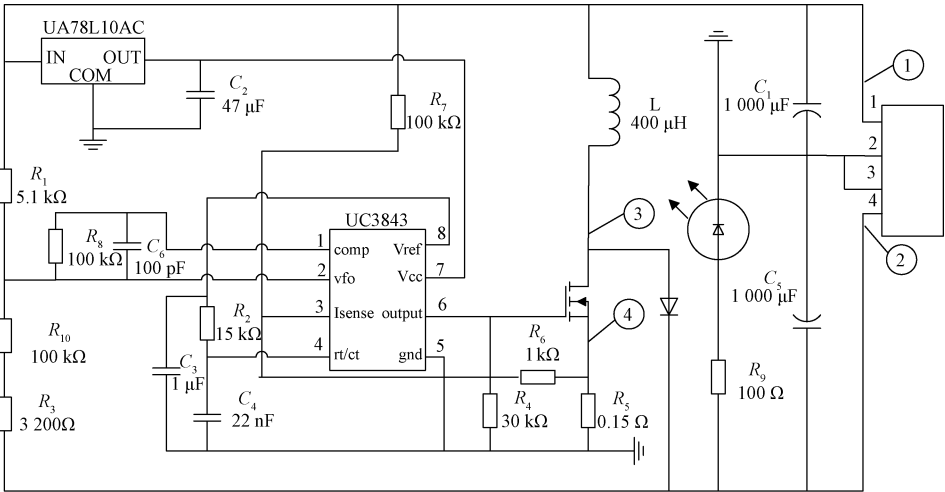


图 9 150 W Boost 电路原理图

Fig. 9 150 W Boost circuit schematic

60%,因此本文对电解电容 C_1 和 C_5 的参数衰退故障进行设定研究,在电容值退化了标称值的 10%~50% 范围内将其退化程度的故障分为 16 种,其中 f11 是正常模式,f12、f13、f14 为 C_1 软故障,f21、f31、f41 为 C_5 软故障,

其余为 C_1 、 C_5 双软故障,其故障设定如表 4 所示。

表 4 电容故障模式设定
Table 4 Capacitor fault mode setting

电容类型	$(C_1/C_5)/\mu\text{F}$	C_1/C_5	故障类别
		退化程度 / %	
f11	988/916	0~10/0~10	1
f12	988/887	0~10/10~20	2
f13	988/653	0~10/30~40	3
f14	988/554	0~10/40~50	4
f21	864/916	10~20/0~10	5
f22	864/887	10~20/10~20	6
f23	864/653	10~20/30~40	7
f24	864/554	10~20/40~50	8
f31	655/916	30~40/0~10	9
f32	655/887	30~40/10~20	10
f33	655/653	30~40/30~40	11
f34	655/554	30~40/40~50	12
f41	546/916	40~50/0~10	13
f42	546/887	40~50/10~20	14
f43	546/653	40~50/30~40	15
f44	546/554	40~50/40~50	16

4.2 测点分析

电力电子电路的故障多采用检测电路输出电压信号的方式进行故障诊断,本文采用 PCI8335A 数据采集卡采集测点电压,其中 1 测点-输入电压、2 测点-输出电压、3 测点-MOS 管漏极电压、4 测点-MOS 管源级电压均包含 C_1 、 C_5 的故障信息,故获取 4 个测点的电压信号可以准确的表现出电路的状态。每个测点采样点数 2 000,每种故障状态采样 50 次,由 4 个测点组成的信号特征,作为判断软故障类别的依据。图 10 为 f33 故障模式下 4 个测点的电压波形图。

4.3 实验分析

本文基于 VMD 分解经验,选择惩罚因子 α 为 2 000,判别精度为 10^{-7} ,通过中心频率观察法,设定分解层数为 7 层,即分解后有 7 层 IMF 分量。然后将每层 IMF 分量降噪后线性重构,提取重构后波形的 12 维时域参数,依次将一类故障模式下 4 个测点的电压信号进行特征提取,获取的 48 维特征参数作为故障诊断的特征向量。图 11 为 f33 故障模式下第 4 测点电压信号的 VMD 分解图。

实验采取功率为 150 W 的 Boost 电路软故障数据进行处理分析,依次将每种故障模式下 4 个测点的电压信号通过 VMD 结合时域参数处理后,获得 800 组 48 维的故障特征向量,将故障特征向量按照 7 : 3 分为训练集和测试集,然后导入本文提出的 ISSA-ELM 分类模型进行

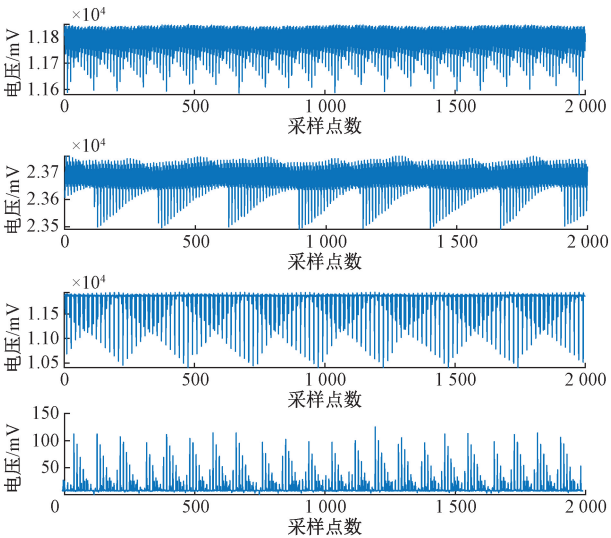


图 10 f33 模式 4 个测点的电压波形
Fig. 10 Voltage waveform of four measuring points in f33 mode




图 11 f33 模式第 4 测点的 VMD 分解图
Fig. 11 VMD exploded view of the fourth measuring point in f33 mode

故障识别,故障诊断过程如图 12 所示。




图 12 故障诊断过程
Fig. 12 Fault diagnosis process

为验证本文所提的 ISSA-ELM 分类模型的优越性,将原始的 ELM、MFO-ELM、WOA-ELM、HHO-ELM、SSA-ELM 与 ISSA-ELM 分类模型进行实验对比。为保证客观性,在实验环境相同的情况下,所有优化算法的种群规模为 20,最大迭代次数为 50 次。实验结果如表 5 所示。

表 5 各分类器的准确率
Table 5 Accuracy of each classifier

分类器	最低准确率/%	最高准确率/%	平均准确率/%
ELM	92.910	96.667	95.083
MFO-ELM	96.250	98.750	97.688
WOA-ELM	96.667	99.167	98.354
HHO-ELM	96.667	100.000	98.396
SSA-ELM	97.917	99.583	98.271
ISSA-ELM	99.167	100.000	99.625

本文选取分类预测错误率作为适应度函数,5 种算法的适应度曲线如图 13 所示。SSA 优化 ELM 的迭代曲线陷入局部最优,错误率为 0.012 5。而 ISSA 优化 ELM 的迭代曲线收敛速度最快,相比于其他 4 种算法,寻优性能更好,能达到最优值 0.004 17。




图 13 5 种算法的适应度曲线

Fig. 13 Adaptability curves of 5 algorithms

在相同环境下,对比 6 种分类模型的准确率结果可知,ELM 的权值和阈值经过群智能算法优化过后,其分




图 15 不同提取方法在不同分类器上的平均分类准确率

Fig. 15 Average classification accuracy of different extraction methods on different classifiers

5 结 论

针对电力电子电路的软故障特征区分度差,不易诊断等问题,提出了 VMD 结合改进麻雀搜索算法优化

类的准确率较原始的 ELM 均有提升。其中 ISSA 优化 ELM 在电力电子电路软故障诊断中性能最稳定,分类精度最高,每次分类准确率均在 99% 以上,体现了 ISSA-ELM 模型的优越性。图 14 为 ISSA-ELM 分类准确率的混淆矩阵。




图 14 ISSA-ELM 模型分类的混淆矩阵

Fig. 14 Mixed matrix of ISSA-ELM model classification

在 Boost 电路软故障实验数据的基础上,本文将 VMD 结合时域参数的故障信号特征提取方法与常见的 EMD、DWT、VMD 结合香农熵以及直接提取故障信号时域参数等特征提取方法进行实验对比,其实验对比结果如图 15 所示。从图 15 可以看出当选取相同原始数据,相同环境,相同分类器时,用这 4 类故障特征提取方法后的故障分类的正确率在绝大部分情况下均低于 VMD 结合时域参数的故障特征提取方法的故障分类的正确率。证明 VMD 结合时域参数的特征提取具有一定优势,可以在一定程度上克服电力电子电路软故障信号区分度差的问题。

ELM 的电力电子电路软故障诊断方法,主要结论如下:

- 1) 将故障信号经 VMD 分解后的 IMF 分量重构并提取时域特征,与现有的特征提取方法相比,获取的信号故障信息更为全面,能克服特征区分度差的问题。

2) 利用 3 种策略将 SSA 进行改进,提升了原算法的收敛精度和跳出局部最优的能力,并在基准函数测试上与 MFO、WOA、HHO、SSA 等群算法对比具有一定的优越性。

3) 利用 ISSA 对 ELM 的权值和阈值进行优化,并与原始的 ELM、SSA-ELM、MFO-ELM、WOA-ELM、HHO-ELM 等模型对比具有更高的分类精度。

在实际电路软故障检测实验中,较高的诊断正确率说明了该方法的可行性,为电力电子电路软故障诊断提供了新思路。

参考文献

- [1] 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.
- [2] LI ZHAN, WHEELER P, WATSON A, et al. A fast diagnosis method for both IGBT faults and current sensor faults in grid-tied three-phase inverters with two current sensors[J]. IEEE Transactions on Power Electronics, 2020, 35(5): 5267-5278.
- [3] XIE D, GE X L. A state estimator-based approach for open-circuit fault diagnosis in single-phase cascaded H-bridge rectifiers [J]. IEEE Transactions on Industry Applications, 2019, 55(2): 1608-1618.
- [4] 刘建强,刘传铎,王铁欧,等. 单相 PWM 整流器 IGBT 及直流侧电容故障诊断方法[J]. 电工技术学报, 2019, 34(S1): 244-257.
LIU J Q, LIU CH D, WANG Y OU, et al. Fault diagnosis method for IGBT and DC-link capacitor of single-phase PWM rectifier[J]. Transactions of China Electrotechnical Society, 2019, 34(S1): 244-257.
- [5] 张鑫,赵建民,李海平,等. 基于 NIC-DWT-WOASVM 的齿轮箱混合故障诊断[J]. 振动与冲击, 2020, 39(11): 146-151, 164.
ZHANG X, ZHAO J M, LI H P, et al. Compound fault diagnosis for gearbox based on NIC-DWT-WOASVM[J], Journal of Vibration and Shock, 2020, 39 (11): 146-151, 164.
- [6] YE X, HU Y, SHEN J, et al. An adaptive optimized TVF-EMD based on a sparsity-impact measure index for bearing incipient fault diagnosis[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 70: 1-11.
- [7] ZOSSO D, DRAG K, ANDRE L, et al. Two-dimensional compact variational mode decomposition [J]. Journal of Mathematical Imaging and Vision, 2017, 58 (2): 294-320.
- [8] SUN J, XING H Y, WU J. Distributed sea clutter denoising algorithm based on variational mode decomposition[J]. Instrumentation, 2020, 7(3): 23-32.
- [9] LU Q, YANG R, ZHONG M, et al. An improved fault diagnosis method of rotating machinery using sensitive features and RLS-BP neural network [J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(4): 1585-1593.
- [10] 徐睿,梁循,齐金山,等. 极限学习机前沿进展与趋势[J]. 计算机学报, 2019, 42(7): 1640-1670.
XU R, LIANG D, QI J SH, et al. Advances and trends in extreme learning machine [J]. Chinese Journal of Computers, 2019, 42(7): 1640-1670.
- [11] 张淑清,苑世钺,姚玉永,等. 基于 ICEEMD 及 AWOA 优化 ELM 的机械故障诊断方法[J]. 仪器仪表学报, 2019, 40(11): 172-180.
ZHANG SH Q, YUAN SH Y, YAO Y Y, et al. Machinery fault diagnosis method based on ICEEMD and AWOA optimized ELM [J]. Chinese Journal of Scientific Instrument, 2019, 40(11): 172-180.
- [12] LUO H, HE C, ZHOU J, et al. Rolling bearing sub-health recognition via extreme learning machine based on deep belief network optimized by improved fireworks[J]. IEEE Access, 2021, 9: 42013-42026.
- [13] XUE J, SHEN B. A novel swarm intelligence optimization approach: Sparrow search algorithm [J]. Systems Science & Control Engineering an Open Access Journal, 2020, 8(1): 22-34.
- [14] 于元灏,杨光永,晏婷,等. 基于 CSSA 与 MCKD 的电机轴承故障提取 [J]. 电子测量技术, 2021, 44 (14): 142-147.
YU Y J, YANG G Y, YAN T, et al. Motor bearing fault extraction based on CSSA and MCKD [J]. Electronic Measurement Technology, 2021, 44(14): 142-147.
- [15] LIU Q, ZHANG Y, LI M, et al. Multi-UAV path planning based on fusion of sparrow search algorithm and improved bioinspired neural network[J]. IEEE Access, 2021, 9: 124670-124681.
- [16] LIU S, DONG L, LIAO X, et al. Application of the variational mode decomposition-based time and time - frequency domain analysis on series DC arc fault detection of photovoltaic arrays[J]. IEEE Access, 2019, 7: 126177-126190.
- [17] 谢国民,黄睿灵,丁会巧. 基于 VMD 样本熵和 KELM 的输电线路故障诊断 [J]. 电子测量与仪器学报,

2019,33(5):73-79.

XIE G M, HUANG R L, DING H Q. Fault diagnosis of transmission lines based on VMD sample entropy and KELM [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(7):73-79.

- [18] 王琇峰,文俊. 基于噪声信号和改进 VMD 的滚动轴承故障诊断[J]. 噪声与振动控制, 2021, 41(2): 118-124.

WANG X F, WEN J. Fault diagnosis of rolling bearings based on noise signal and improved VMD[J]. Noise and Vibration Control, 2021, 41(2):118-124.

- [19] 毛清华,张强. 融合柯西变异和反向学习的改进麻雀算法[J]. 计算机科学与探索, 2021, 15(6): 1155-1164.

MAO Q H, ZHANG Q. Improved sparrow algorithm combining cauchy mutation and opposition-based learning[J]. Journal of Frontiers of Computer Science and Technology, 2021, 15(6):1155-1164.

- [20] 高文欣,刘升,肖子雅,等. 柯西变异和自适应权重优化的蝴蝶算法[J]. 计算机工程与应用, 2020, 56(15): 43-50.

GAO W X, LIU SH, XIAO Z Y, et al. Butterfly optimization algorithm based on Cauchy variation and adaptive weight [J]. Computer Engineering and Applications, 2020, 56(15):43-50.

作者简介



朱文昌, 现为安徽理工大学硕士研究生, 主要研究方向为电力电子系统故障诊断。
E-mail: 836008524@qq.com

Zhu Wenchang is a M. Sc. candidate at Anhui University of Science and Technology. His main research interests include power electronic circuit fault diagnosis and prediction.



李振璧(通信作者), 1982 年于山东大学获得学士学位, 1996 年于安徽理工大学获得硕士学位, 现为亳州学院教授, 主要研究方向为人工智能与模式识别。
E-mail: 471600285@qq.com

Li Zhenbi (Corresponding author) received his B. S. degree from Shandong University in 1982 and M. S. degree from Anhui University of Technology in 1996. He is now a professor at Bozhou College, his main research interests include artificial intelligence and pattern recognition.



姜媛媛, 2018 年于南京航空航天大学获得博士学位, 现为安徽理工大学教授, 主要研究方向为电力电子系统故障诊断。
E-mail: jyyl672@163.com

Jiang Yuanyuan received her Ph. D. from Nanjing University of Aeronautics and Astronautics in 2018. Now she is a professor at Anhui University of Science and Technology. Her main research interest includes fault diagnosis for power electronic systems.