

DOI:10.19651/j.cnki.emt.2209529

基于 MHHO-BP 算法的 DC-DC 电路软故障诊断 *

王 力^{1,3} 李振壁^{1,2} 姜媛媛^{1,3}(1. 安徽理工大学电气与信息工程学院 淮南 232001; 2. 亳州学院电子与信息工程系 亳州 236800;
3. 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 电路软故障诊断中特征提取困难和分类准确率低的问题,提出了一种基于多策略改进哈里斯优化算法-反向传播 MHHO-BP 神经网络的故障诊断方法。该方法通过 VMD 对故障信号进行处理,提取其时域和频域特征作为故障向量,采用 MHHO 算法优化 BP 神经网络的权值和阈值,建立 DC-DC 电路的 VMD-MHHO-BP 软故障诊断模型。实验结果表明,对于 DC-DC 电路软故障,该方法相较于鲸鱼优化算法(WOA)和蝴蝶优化算法(BOA)优化 BP 神经网络,其诊断效果好,准确率高。

关键词: BP 神经网络; 故障诊断; 变分模态分解; 哈里斯鹰优化算法; DC-DC 电路

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

Soft fault diagnosis of DC-DC circuits based on MHHO-BP algorithm

Wang Li^{1,3} Li Zhenbi^{1,2} Jiang Yuanyuan^{1,3}

(1. College of Electrical and Information Engineering, Anhui University of Science and Technology, Huainan 232001, China;
2. Department of Electronic and Information Engineering, Bozhou University, Bozhou 236800, China; 3. Institute of Environmentally
Friendly Materials and Occupational Health (Wuhu), Anhui University of Science and Technology, Wuhu 241003, China)

Abstract: To address the problems of difficult feature extraction and low classification accuracy in soft fault diagnosis of DC-DC circuits, a fault diagnosis method based on multi-strategy improved Harris optimization algorithm-back propagation (MHHO-BP) neural network is proposed. The method processes the fault signal by VMD, extracts its time-domain and frequency-domain features as the fault vector, and uses the MHHO algorithm to optimize the weights and thresholds of the BP neural network to establish a VMD-MHHO-BP soft fault diagnosis model of DC-DC circuits. The experimental results show that for soft faults of DC-DC circuits, the method has good diagnostic effect and high accuracy compared with the Whale Optimization Algorithm (WOA) and Butterfly Optimization Algorithm (BOA) optimized BP neural network.

Keywords: backward propagation neural network; fault diagnosis; variational modal decomposition; harris hawk optimization algorithm; DC-DC circuit

0 引言

DC-DC 电路作为重要电力电子电路之一,已经广泛应用于电动汽车、可再生能源系统和航空航天动力系统等领域^[1-2]。DC-DC 电路中的元器件受到参数退化的影响会使电路的整体功能逐渐下降^[3],这类故障称为软故障或参数性故障。因此,快速有效地完成 DC-DC 电路的软故障诊断,维持电力设备的正常运行具有重要意义。

实现 DC-DC 电路软故障诊断的关键是故障信号的特

征提取以及故障诊断算法^[4-8]。故障特征提取方面,文献[9]提出一种改进的集成经验模态分解(ensemble empirical mode decomposition, EEMD),在分解过程中自适应地选择附加噪声的幅值和筛选数,有效避免模态混叠问题。但 EEMD 仍属于递归分解模式,无法从根本上解决模态混叠和端点效应。文献[10]提出通过离散小波变换(discrete wavelet transformation, DWT)获得不同频率和时间尺度下的故障信息,充分反映故障特征,但是小波基函数需要人为选择。变分模态分解(variational mode

收稿日期:2022-04-07

* 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(AI.W2020YF18)项目资助

decomposition, VMD)能够有效解决上述问题,被广泛应用于故障特征提取。

电路故障诊断算法方面^[11],反向传播(back propagation, BP)神经网络因其高度自适应和泛化能力强的优点被广泛应用。文献[12]使用改进的 BP 神经网络用于模拟电路的故障诊断,诊断率较基本的 BP 神经网络高。文献[13]利用免疫遗传算法(immune genetic algorithm, IGA)优化 BP 网络诊断方法,实现对模拟电路渐变性故障的诊断。BP 神经网络在电路故障诊断中应用广泛,但在算法迭代过程寻得的权值阈值参数未达到最优。

综上,本文提出一种多策略改进哈里斯鹰算法(multi-strategy harris hawks optimization, MHHO)优化 BP 神经网络的 DC-DC 电路软故障诊断方法。首先,基于 VMD 对采集的故障信号分解,重组主要信号的模态并提取其时域和频域特征来构造特征向量集合。其次,利用 MHHO 对 BP 参数寻优过程进行优化,得到最优参数模型。最后,应用于 DC-DC 电路软故障实现高效诊断。

1 理论基础

1.1 变分模态分解

变分模态分解作为频域方法的分析方法,是将待分解的信号转换为变分模态的分解,其核心思想是构建以及求解变分问题,具体原理及步骤参考文献[14]。通过模态及中心频率的匹配更新,从而实现信号频率和带宽有效分离。因为 VMD 使用的分解模型主要由维纳滤波构成,所以对于噪声信号具有良好的自适应性,可以很好地反映信号的特征^[15-16]。

采集的故障信号经过 VMD 有效分解后,得到主要信号的模态进行重组,提取其时域和频域特征,组成特征向量。

1.2 多策略改进的哈里斯鹰算法

哈里斯鹰优化(harris hawks optimization, HHO)算法因其原理简单、易编程实现和调参较少等特点已经广泛运用在神经网络的训练过程中^[17],但是 HHO 算法存在收敛精度低和易陷入局部寻优的问题。因此,本文提出了多策略改进的 HHO 算法。

1) HHO 算法

HHO 算法于 2019 年提出,其灵感来源于哈里斯鹰的合作觅食行为。在不同情形下执行不同的策略,来模拟真实世界中哈里斯鹰捕食猎物的复杂过程。在 HHO 中,候选解是哈里斯鹰的位置向量集合,而猎物向量集合随迭代更新越来越接近最优解,其原理可参考文献[18]。

2) 多策略改进的 HHO 算法

针对 HHO 在收敛速度和局部寻优存在的问题,提出了 MHHO 算法进行改进。首先,在全局搜索阶段使用精英准反射学习机制,增加初始种群的质量以提高整体搜索能力;其次,采用 Circle 混沌调整 HHO 算法中控制局部开

发的关键参数 v ,最后,引入分段非线性收敛因子和基于正弦的自适应权值因子,来提高 HHO 算法的局部个体寻优能力。

(1) 精英准反射学习机制

针对 HHO 优化算法易陷入局部最优的缺点,使用精英准反射学习机制来增加种群的多样性以提高全局搜索能力。Tizhoosh^[19] 和 Rahnamayan 等^[20] 分别提出了反向学习(opposition-based learning, OBL)机制和准反向学习(quasi-opposition-based learning, QOBL)机制,其中的反向解和准反向解比当前解在全局搜索最优解更加有效。Ewees 等^[21-22] 在 OBL 和 QOBL 的基础上,提出新的准反射学习(quasi-reflection-based learning, QRBL)机制,可以在全局搜索阶段更快地寻找到最优解。

定义 1(准反射解) 设在 D 维搜索空间中当前种群的一个可行解为 $X = (x_1, x_2, \dots, x_D)$, 其准反射解为 $X^{qr} = (\bar{x}_1, \bar{x}_2, \dots, \bar{x}_D)$, 准反射解 X^{qr} 的定义为:

$$x_i^{qr} = rand((lb_i + ub_i)/2, x_i) \quad (1)$$

式中: $rand((lb_i + ub_i)/2, x_i)$ 是均匀分布在 $(lb_i + ub_i)/2$ 和 x_i 之间的随机数, $(lb_i + ub_i)/2$ 表示的是区间 $[lb_i, ub_i]$ 的中心, $x_i \in [lb_i, ub_i]$ 且 $\forall i \in 1, 2, \dots, d$ 。

为了在数轴上更好地展示解的定义,图 1 给出了点 x 、反向点 x_o 、准反向点 x^{qr} 和准反射点 x^{qqr} 在数轴上的相对位置。

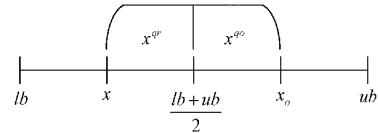


图 1 各个点在数轴上的相对位置

本文基于精英准反射学习(elite quasi-reflection-based learning, EQRBL)机制,用于 HHO 算法中的种群初始化与下一次迭代更新后种群位置的确定。EQRBL 机制利用精英个体具有更多信息的优势,先通过随机种群中生成准反射种群,计算并比较两个种群的适应度值,选择最好的 N 个个体作为新生的精英种群,提升了种群的质量和多样性,避免算法早熟。

定义 2(精英准反射解) 设当前种群中的普通个体的普通解为 $X_{i,j} = (x_{i,1}, x_{i,2}, \dots, x_{i,D})$, 则其精英准反射解为 $X_{i,j}^E = (x_{i,1}^E, x_{i,2}^E, \dots, x_{i,D}^E)$, 其定义为:

$$X_{i,j}^E = \begin{cases} X_{i,j} + (M_j + X_{i,j}) \times r, & X_{i,j} < M_j \\ M_j + (X_{i,j} - M_j) \times r, & \text{其他} \end{cases} \quad (2)$$

式中: $i \in 1, 2, \dots, N$; $j \in 1, 2, \dots, D$, N 为种群大小, D 为问题搜索维度。 r 为区间 $[0, 1]$ 上的一个随机数, $M_j = (lb_j + ub_j)/2$ 。

(2) Circle 映射

Circle 映射被用来生成混沌序列,具有非线性,随机性和初值的敏感依赖性^[23]。经过研究证明,混沌序列多用于

进行种群初始化或者作为算法过程中的扰动,本文采用 Circle 映射来调整 HHO 算法中关键参数 v 的取值。 v 的公式更新如下:

$$v_{i+1} = \text{mod}(v_i + 0.3 - \frac{0.5}{2\pi} \times \sin(2\pi x_i), 1) \quad (3)$$

(3) 分段非线性收敛因子

HHO 中的参数 E 控制着全局搜索和局部开发的转换,由公式 $E_1 = 2(1-t/T)$ 可知,随迭代次数的增加收敛因子 E_1 呈线性下降的趋势。迭代过程中,递减变化相同使得算法在前期搜索和后期开发失去平衡。而且 HHO 真实寻优过程是一种非线性,而线性递减则降低了算法的灵活寻优能力。因此引入一种分段非线性收敛因子来控制算法的两个阶段,其公式更新如下:

$$E_1 = \begin{cases} 2 - \sin(\pi \times \frac{t}{T}), & t \leq 0.5T \\ \cos(\pi \times \frac{t - 0.5T}{T}), & \text{其他} \end{cases} \quad (4)$$

(4) 基于正弦变化的自适应权重因子

以往的研究表明,算法中加入权重在寻找问题最优解时有一定作用。为了局部开发和全局搜索之间关系的平衡,提升算法的灵活性,引入了基于正弦变化的自适应权值因子更新哈里斯鹰在算法中的位置,其数学表达式为:

$$w(t) = \sin(\pi \times \frac{t - 0.5T}{T})/2 + 0.5 \quad (5)$$

1.3 MHHO 算法性能评估

对自然界的简单行为进行模拟而形成的算法称为元启发式算法^[24-25],蝴蝶优化算法(butterfly optimization algorithm, BOA)^[26]和鲸鱼优化算法(whale optimization algorithm, WOA)^[27],是新颖且寻优效果较好的元启发式算法,与 HHO 相似,都在故障诊断等领域运用。为检验 MHHO 的性能,因此采用 BOA、WOA、HHO 和 MHHO 四种算法进行性能评估。其中测试函数选取 Schwefel's Problem 单峰函数和 Rastrigin 多峰函数,实验参数设置如下:种群规模为 25,迭代次数为 450,分别对算法运行 30 次主循环后,测试结果如图 2 和 3 所示。

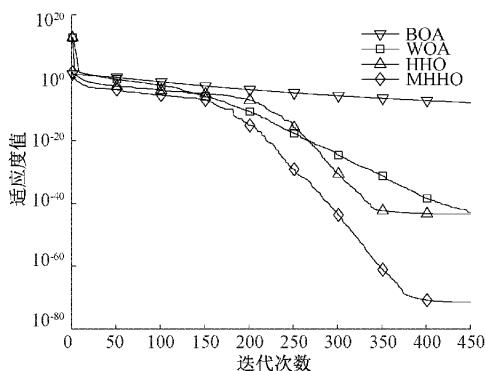


图 2 Schwefel's Problem 函数迭代曲线

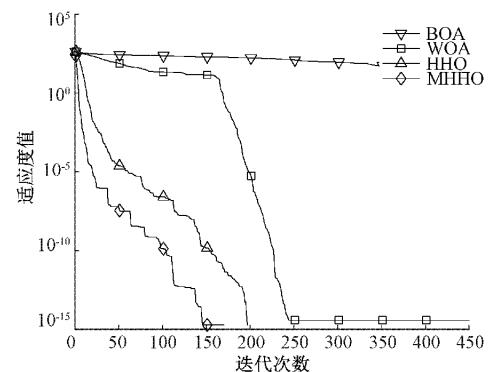


图 3 Rastrigin 函数迭代曲线

如图 2 所示,MHHO 算法求解 Schwefel's Problem 函数时,收敛精度和速度优于 BOA、WOA 和 HHO 算法。在图 3 求解 Rastrigin 函数时,MHHO 的收敛速度最快,说明 MHHO 算法在全局搜索和局部开发的能力更强。

1.4 基于 MHHO-BP 故障诊断

为了实现 DC-DC 电路的高效精准诊断,本文提出了基于 MHHO-BP 神经网络的故障诊断方法。该方法从故障特征提取及分类算法两方面考虑,解决了 DC-DC 电路软故障特征提取困难和诊断率低的问题。首先,基于电路故障信号利用 VMD 提取故障特征,再采用 MHHO-BP 分类算法识别 DC-DC 电路软故障。其中,MHHO-BP 分类算法主要思想为利用 MHHO 算法优化 BP 神经网络的权值与阈值,得到最优参数组合。VMD-MHHO-BP 神经网络模型的故障诊断流程如图 4 所示,具体步骤如下:

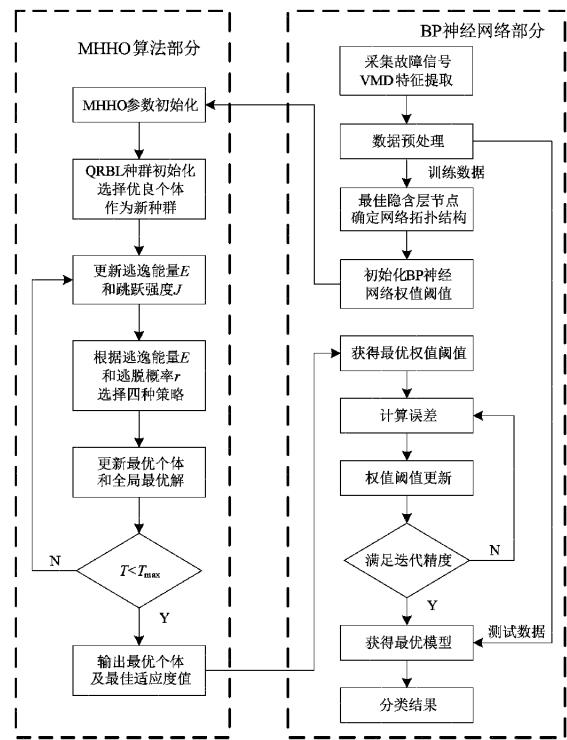


图 4 VMD-MHHO-BP 网络模型故障诊断流程

Step1: 信号采集。采集 DC-DC 电路在不同故障下的电压故障信号;

Step2: 信号分解。使用 VMD 进行特征提取;

Step3: 确定网络结构。根据提取特征的维度和对应的故障类别确定输入和输出节点个数, 使用经验公式确定隐含层节点数;

Step4: MHHO 优化权值阈值。采用 MHHO 算法优化 BP 神经网络的权值和阈值参数;

Step5: 故障诊断。应用优化后的 BP 神经网络模型, 将

特征提取中测试样本作为 BP 神经网络的输入, 则模型输出为待测电路的诊断类别。

2 DC-DC 电路软故障诊断

2.1 DC-DC 电路软故障参数分析

实验中的测试电路为 150 W DC-DC 升压电路, 其用 UC3842 芯片控制电路进行 DC-DC 转换。正常工作状态下, 电路的输入电压为 10~32 V, 输出电压为 12~35 V。DC-DC 电路原理图如图 5 所示。

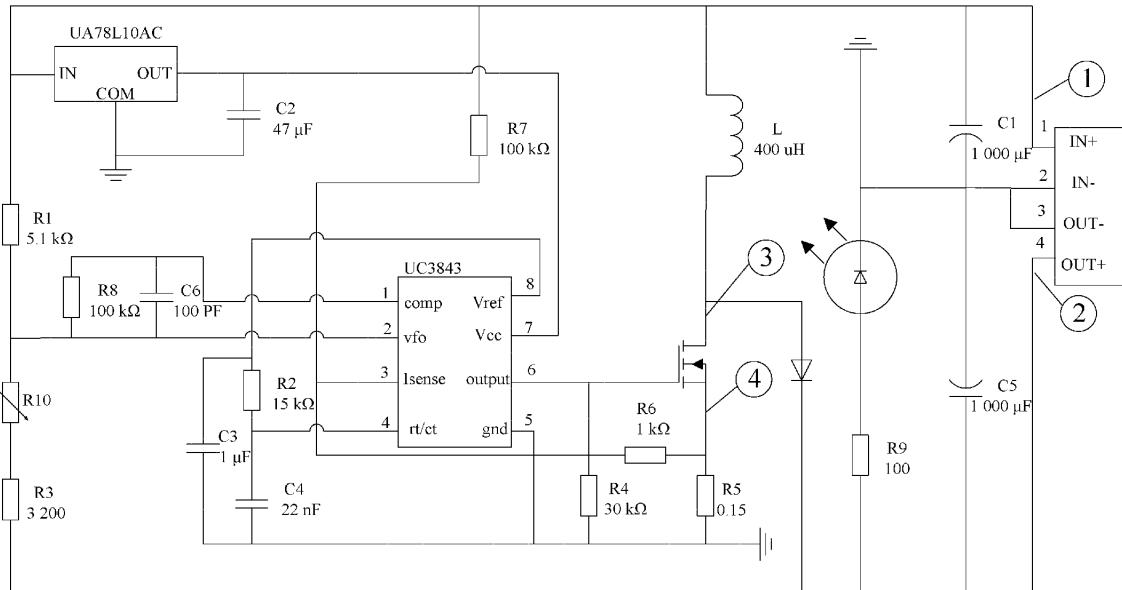


图 5 150 W DC-DC Boost 电路原理图

在电力电子电路的元器件中, 电解电容的损耗率和故障率达到 60%^[28], 所以需要针对电解电容失效的问题进行研究。在实验设置中, 使用常见的电解电容来模拟真实过程中电容的退化, 当电容变化时, 电路中输出电压和电流都会发生变化, 选择的电解电容 C1 和 C5 的标称值均为 1 000 μF, 其容差范围约为 10%^[29]。本文选择的电容容值在其标称值下退化 10%~40%, 并且与常见的电容值相结合, 共设置 16 种电路软故障模式, 如表 1 所示。

考虑测量的便利性及对故障的敏感性, 选择了测点 1~4 的电压信号作为故障信号, 测点 1~4 分别为输入电压、输出电压、MOS 管漏极电压, 和 MOS 管源极电压。如表 1 所示的 16 种电容软故障模式下, 各采集 50 组数据, 其中 f11 电路故障模式下 4 个测点原始波形如图 6 所示。

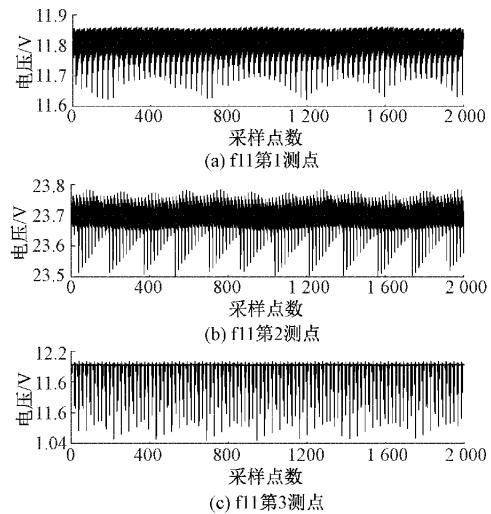


表 1 软故障模式设置表

模式	C1/C5/ μF	标签	模式	C1/C5/ μF	标签
f11	988/916	F1	f31	655/916	F9
f12	988/887	F2	f32	655/887	F10
f13	988/653	F3	f33	655/653	F11
f14	988/554	F4	f34	655/554	F12
f21	864/916	F5	f41	546/916	F13
f22	864/887	F6	f42	546/887	F14
f23	864/653	F7	f43	546/654	F15
f24	864/554	F8	f44	546/554	F16

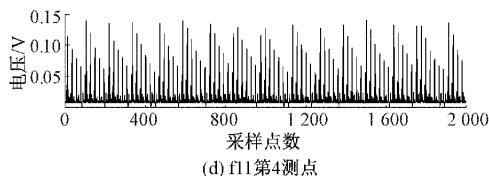


图 6 f11 各测点原始波形

2.2 实验结果及分析

1) 基于特征提取方法的对比分析

通过 DWT、EMD、EEMD 以及 VMD 四种方法提取 13 维电路故障特征, 13 维特征具体为电压信号的最大值、最小值、中位数值、平均值、均方根、峰值、峰值因子、波形因子、脉冲因子、裕度因子、重心频率、频率方差和频率均方差, 在 BP 神经网络下的正确率如表 2 所示。其中参数设置为: DWT 中分解层数设置为 5 层, VMD 中惩罚因子 α 为 2 000, 判别精度 ϵ 为 10^{-7} , 在设置 VMD 分解的层数不当会引起过分解或欠分解情况, 采用中心频率观察法发现选择层数为 7 时, 效果最好且不会出现模态混叠现象。

表 2 不同特征方法下 BP 神经网络模型的正确率

提取方法	测试样本		
	样本数量	正确数	正确率/%
DWT	160	138	86.25
VMD	160	153	95.63
EMD	160	149	93.13
EEMD	160	138	86.25

由表 2 可知, 各种特征方法下 BP 神经网络模型的正确率中, VMD 方法的正确率最高, 达到 95.63%, 其次为 EMD 方法, 正确率为 93.13%, 而 EEMD 和 DWT 方法正确率都为 86.25%, 证明了 VMD 方法进行特征提取的有效性。本文基于 VMD 方法来进行电压信号的特征提取, 组成特征向量, 实现高效诊断。

2) BP 神经网络最佳隐含层层数的确立

BP 神经网络最佳隐含层个数可由经验公式确定, 经过 VMD 特征提取后, 特征数据结构为 800×52 , 标签的数据结构为 800×16 , 即输入层神经元个数为 52 个, 输出层神经元个数为 16 个。通过上面四种特征提取方法来评估 BP 模型, 经过大实验验证 BP 参数设置如下效果最好。即训练迭代次数为 100, 学习速率为 10^{-2} , 训练目标最小误差为 10^{-7} 。不同特征提取方法下 BP 神经网络中隐含层个数对应的准确率如表 3 所示。

由表 3 可知, 最佳隐含层的数目在区间 [9, 18] 之间得到。在各种特征提取方法中, VMD 方法在隐含层个数为 14 时, 准确率达到了最高为 99.69%, 而 DWT、EMD、EEMD 提取方法则都是在隐含层个数为 18 时达到其最高的准确率, 分别为 97.19%、91.72% 和 93.6%。可知在使

表 3 BP 神经网络中隐含层个数对应的准确率

隐含层 个数	特征提取方法 Acc/%			
	DWT	EMD	EEMD	VMD
9	76.88	83.59	77.66	68.91
10	70.00	86.72	66.41	87.81
11	82.97	90.47	82.81	98.75
12	91.41	96.56	89.84	93.75
13	89.53	86.56	85.47	94.53
14	93.13	96.25	89.38	99.69
15	92.97	98.75	90.31	99.38
16	92.19	95.63	91.41	99.53
17	91.88	89.38	90.78	99.22
18	93.59	97.19	91.72	99.53

用 VMD 提取特征作为输入层时, BP 神经网络结构因较少的隐含层个数及最高的准确率完成诊断的过程, 减少了计算量。

3) 基于分类器的对比分析

为了验证 BP 神经网络的优势, 使用 BP 神经网络、概率神经网络 (probabilistic neural networks, PNN)、支持向量机 (support vector machines, SVM) 和极限学习机 (extreme learning machine, ELM) 作为分类器进行比较。其中实验参数设置如下: PNN 的分布密度 spread 为 0.1, SVM 的核函数选用径向基函数, ELM 的网络结构为 [52, 10 000, 16], 不同分类器的分类正确率如表 4 所示。

表 4 不同分类器下的正确率

分类器	测试样本		
	样本数量	正确数	正确率/%
BP	160	155	96.88
PNN	160	130	81.25
SVM	160	153	95.63
ELM	160	150	93.75

由表 4 可知, 在相同的故障特征输入下, 其中 BP 神经网络的正确率最高, 达到了 96.88%。PNN 因其网络特性并不适用于大型网络, 因而正确率最低, 为 81.25%。最接近 BP 神经网络的正确率的是 ELM 和 SVM, 分别为 93.75% 和 95.63%, 但是其诊断效果仍低于 BP 神经网络。

4) 对比实验

电压信号经过 VMD 进行处理后得到特征向量, 经验公式确定隐含层层数的最优值。使用 BOA-BP^[30] 网络模型 WOA-BP^[31] 网络模型和基本的 HHO-BP 网络模型与 MHHO-BP 网络模型下, 得到故障诊断的结果。其中各种算法的设置为: 种群数量为 20, 迭代次数为 20, 上下边界设

为区间 $[-5, 5]$; BOA 中感觉因子 c 为 0.01, 幂指数 a 为 0.1, 转换概率 p 为 0.8; 其迭代过程中最佳适应度值曲线对比如图 7 所示。

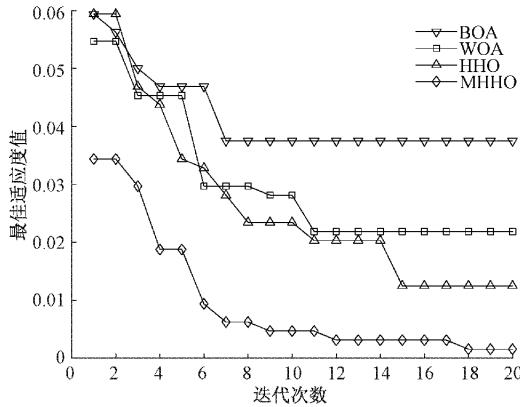


图 7 智能算法迭代曲线对比图

图 7 为 3 种智能算法分别是 BOA、WOA、基本的 HHO 和 MHHO 经过 20 次迭代后的最佳模型训练曲线, 显而易见 MHHO 算法的适应度曲线相比 BOA、WOA 和基本的 HHO 算法, 在收敛速度和局部寻优方面能力更强, 也就意味着使用改进后的 HHO 算法, 迭代寻找时的 BP 神经网络的权值和阈值是最优的, 这样也使得电路故障分类时正确诊断数量最多, 从而准确率也达到最高。

对 DC-DC 电路进行对比实验, 具体结果如表 5 所示。由表 5 可知, 采用 VMD 方法提取电路信号的特征作为特征向量, 改进后的方法进行故障诊断, 正确诊断数量最多, 诊断效果最好, 达到了 99.38%, 因此将所提出的方法应用于 DC-DC 电路软故障诊断会更加准确和有效。

表 5 对比试验诊断率

文献	诊断方法	样本	诊断	诊断率/
		数量	数量	%
[12]	Kurtosis, skewness+BP	160	129	80.63
[13]	WPA+IGA-BP	160	135	84.38
[30]	EEMD+BOA-BP	160	133	83.13
[31]	WOA-BP	160	136	85.00
改进前	VMD+HHO-BP	160	158	98.75
改进后	VMD+MHHO-BP	160	159	99.38

为了更加直观地表示 MHHO-BP 神经网络中每类故障的详细诊断结果, 测试集数据输出故障分类的混淆矩阵如图 8 所示。其中, 混淆矩阵的横轴和纵轴分别表示测试数据的诊断类别和真实类别, 对角线则为每类故障准确识别的个数。图 8 中, MHHO-BP 网络模型仅有一处故障误判, 将真实类别的第 14 类故障诊断为第 6 类故障, 证明了所改进的算法对于 DC-DC 电路故障诊断具有良好的分类识别效果。

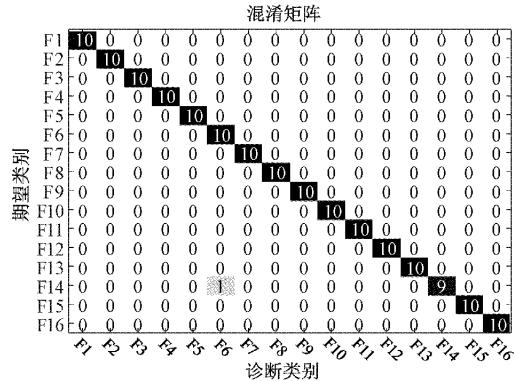


图 8 MHHO-BP 测试集故障分类混淆矩阵

3 结论

本文针对 DC-DC 电路软故障诊断中特征提取困难和分类准确率低的问题, 提出了一种基于 MHHO-BP 的故障诊断方法, 通过理论分析与仿真验证得出以下结论:

针对 DC-DC 电路软故障中特征提取困难的问题, 采用了 VMD 方法来提取故障特征。基于 VMD、EMD、EEMD 和 DWT 四种特征提取方法下的 BP 神经网络中, VMD 方法的诊断精度最高。

针对 DC-DC 电路软故障中诊断准确率低的问题, 提出了 MHHO 优化 BP 神经网络的权值阈值的方法, 其中 BP 神经网络中隐含层个数由经验公式确定。经过对比实验可知, MHHO-BP 神经网络的诊断准确率最高。实验结果表明, 本文所提方法可以实现 DC-DC 电路软故障的高效诊断, 具有一定的实用价值。

VMD 算法中采用了中心频率观察法, 但这只能解决分解层数 k 值的优化, 并没有考虑到分解层数 k 与惩罚因子 α 之间的相互作用对 VMD 分解的影响。下一步的研究工作是同时优化 VMD 算法的参数组合 $[k, \alpha]$, 进一步提高 DC-DC 电路软故障诊断的准确率。

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] KUMAR G K, ELANGOVAN D. Review on fault-diagnosis and fault-tolerance for DC-DC converters [J]. IET Power Electronics, 2020, 13(1): 1-13.
- [3] 任磊, 韦徵, 龚春英, 等. 电力电子电路功率器件故障特征参数提取技术综述 [J]. 中国电机工程学报, 2015, 35(12): 3089-3101.
- [4] 王熙乾, 高雪莲, 史丽鹏. 基于 WOA-PNN 算法的电力电子电路故障诊断分析 [J]. 微电子学, 2020, 50(2): 232-235.
- [5] 王文凯, 邓斌. 基于 DAE-IPSO-SVM 的电缆早期故障

- 识别方法[J]. 国外电子测量技术, 2021, 40(8): 29-35.
- [6] YU Y, JIANG Y, LIU Y, et al. Incipient fault diagnosis method for DC-DC converters based on sensitive fault features[J]. IET Power Electronics, 2020, 13(19): 4646-4658.
- [7] 徐钊, 张一童, 潘震, 等. DC-DC 变换器的典型故障分类方法研究[J]. 西北工业大学学报, 2021, 39(1): 71-76.
- [8] 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.
- [9] WANG C S, SHA C Y, SU M, et al. An algorithm to remove noise from locomotive bearing vibration signal based on self-adaptive EEMD filter[J]. Journal of Central South University, 2017, 24(2): 478-488.
- [10] GU K, ZHANG Y, LIU X, et al. DWT-LSTM-based fault diagnosis of rolling bearings with multi-sensors[J]. Electronics, 2021, 10(17): 1-13.
- [11] 赵宁. 基于神经网络的三相整流电路故障诊断策略研究[J]. 国外电子测量技术, 2021, 40(3): 88-93.
- [12] XIE T, HE Y. Fault diagnosis of analog circuit based on high-order cumulants and information fusion[J]. Journal of Electronic Testing, 2014, 30(5): 505-514.
- [13] 王力, 刘子奇. WPA-IGA-BP 神经网络的模拟电路故障诊断[J]. 系统工程与电子技术, 2021, 43(4): 1133-1143.
- [14] DRAGOMIRETSKIY K, ZOSKO D. Variational mode decomposition [J]. IEEE Transactions on Signal Processing, 2014, 63(3): 531-544.
- [15] 刘长良, 武英杰, 甄成刚. 基于变分模态分解和模糊 C 均值聚类的滚动轴承故障诊断[J]. 中国电机工程学报, 2015, 35(13): 3358-3365.
- [16] 姜媛媛, 程浩, 崔江, 等. VMD 小波能量的光伏逆变器软故障诊断[J]. 电力系统及其自动化学报, 2018, 30(11): 19-25.
- [17] FAN C, ZHOU Y, TANG Z. Neighborhood centroidopposite-based learning Harris Hawks optimization for training neural networks [J]. Evolutionary Intelligence, 2021, 14: 1847-1867.
- [18] AAHA B, SM C, HF D, et al. Harris Hawks optimization: Algorithm and applications[J]. Future Generation Computer Systems, 2019, 97: 849-872.
- [19] TIZHOOSH H R. Opposition-based learning: A new scheme for machine intelligence [C]. International Conference on Computational Intelligence for Modelling, Control & Automation, IEEE, 2005: 69-701.
- [20] RAHNAMAYAN S, TIZHOOSH H R, SALAMA M. Quasi-oppositional differential evolution [C]. 2007 IEEE Congress on Evolutionary Computation, IEEE, 2007.
- [21] FAN Q, CHEN Z, XIA Z. A novel quasi-reflected Harris hawks optimization algorithm for global optimization problems [J]. Soft Computing, 2020, 24(13): 14825-14843.
- [22] EWEES A A, ELAZIZ M A, HOUSSEIN E H. Improved grasshopper optimization algorithm using opposition-based learning [J]. Expert Systems with Applications, 2018, 112: 156-172.
- [23] 张达敏, 徐航, 王依柔, 等. 嵌入 Circle 映射和逐维小孔成像反向学习的鲸鱼优化算法[J]. 控制与决策, 2021, 36(5): 1173-1180.
- [24] 汤安迪, 韩统, 徐登武, 等. 混沌精英哈里斯鹰优化算法[J]. 计算机应用, 2021, 41(8): 2265-2272.
- [25] 郭雨鑫, 刘升, 高文欣, 等. 多策略改进哈里斯鹰优化算法[J]. 微电子学与计算机, 2021, 38(7): 18-24.
- [26] ARORA S, SINGH S. Butterfly optimization algorithm: a novel approach for global optimization [J]. Soft Computing, 2019, 23(3): 715-734.
- [27] MIRJALILI S, LEWIS A. The whale optimization algorithm [J]. Advances in Engineering Software, 2016, 95: 51-67.
- [28] YANG S, XIANG D, BRYANT A, et al. Condition monitoring for device reliability in power electronic converters: A review [J]. IEEE Transactions on Power Electronics, 2010, 25(11): 2734-2752.
- [29] XIA Y, ROY J, AYYANAR R. A capacitance-minimized, doubly grounded transformer less photovoltaic inverter with inherent active power decoupling [J]. IEEE Transactions on Power Electronics, 2017, 32(7): 5188-5201.
- [30] 陈芳, 张志强, 李扉, 等. 基于 EEMD 分解与 BOA 算法优化神经网络的密云水库大阁水文站径流预测[J]. 西北林学院学报, 2021, 36(6): 188-194.
- [31] 马宏光, 曾国辉, 黄勃. 基于 WOA-BP 的压力变送器温度补偿研究[J]. 仪表技术与传感器, 2020(6): 33-36.

作者简介

王力, 硕士研究生, 主要研究方向为电力电子电路故障诊断。

E-mail: 1499728325@qq.com

李振璧(通信作者), 硕士研究生, 教授, 主要研究方向为计算机视觉、智能诊断及故障预测。

E-mail: 471600285@qq.com

姜媛媛, 博士研究生, 教授, 主要研究方向为电力电子电路故障诊断与预测技术研究。

E-mail: jyyl672@163.com