

DOI: 10.13382/j.jemi.B2104919

基于 LSSA 优化 DBN 的双有源桥变换器 开路故障诊断*

赵莹莹 何怡刚 杜博伦 邢致恺 汪磊
(武汉大学电气与自动化学院 武汉 430072)

摘要:针对双有源桥(dual active bridge, DAB)变换器中 IGBT 开路故障诊断精度较低的问题,提出基于莱维飞行麻雀搜索算法(Levy sparrow search algorithm, LSSA)优化深度信念网络(deep belief network, DBN)的故障诊断方法。首先,利用莱维飞行策略改进麻雀搜索算法的收敛速度和全局优化能力。然后将 DBN 的均方差作为适应度函数,利用 LSSA 寻找 DBN 的最优隐藏层单元数,根据得到的最优值建立 DBN 故障诊断模型。通过 RT-LAB 搭建 DAB 变换器半实物仿真系统,对变压器漏感电流信号进行故障诊断,在收敛速度、适应度值和诊断精度指标方面进行对比分析。实验结果表明诊断模型可以有效诊断 DAB 变换器开路故障,且诊断精度达到 99%。

关键词: 双有源桥变换器;深度信念网络;麻雀搜索算法;莱维飞行策略;故障诊断

中图分类号: TN358;TM46 **文献标识码:** A **国家标准学科分类代码:** 470.40

Open circuit fault diagnosis of dual active bridge converterbased on LSSA optimized DBN

Zhao Yingying He Yigang Du Bolun Xing Zhikai Wang Lei
(School of Electrical Engineering and Automation, Wuhan University, Wuhan 430072, China)

Abstract: Aiming at the low fault diagnosis accuracy of IGBTs' open circuit fault in dual active bridge (DAB) converter, a fault diagnosis method based on the Levy sparrow search algorithm (LSSA) to optimize the deep belief network (DBN) is proposed. First, the Levy flight strategy improves the convergence speed and global optimization capability of the SSA. Then, the mean square error function of the DBN is taken as the fitness function. The LSSA finds the optimal number of hidden layer units of DBN. According to the optimal number of hidden layers, we construct a DBN open-circuit fault diagnosis model. Through building the hardware-in-the-loop simulation system of DAB converter in RT-LAB, the method uses the transformer leakage current as the diagnostic signal. The comparative analysis is conducted on the convergence speed, fitness value index and diagnosis accuracy. The experiment results show that the diagnosis model can diagnose the open-circuit fault of the DAB converter effectively, and the fault diagnosis accuracy achieves 99%.

Keywords: dual active bridge converter; deep belief network; sparrow search algorithm; levy flight strategy; fault diagnosis

0 引言

双有源桥(dual active bridge, DAB)变换器具有电气隔离和能量双向流动特性,广泛应用于电动汽车、储能系

统、分布式发电和直流输电领域^[1-4],承担着电能变换和能量传递的作用。然而可靠性是电力电子变换器面临的重要问题,电力电子变换器发生故障时会造成巨大的经济损失和人身伤害。电力电子变换器中 IGBT 失效率达 38%^[5],是最易损坏的器件之一。IGBT 短路故障会对变

收稿日期: 2021-11-19 Received Date: 2021-11-19

* 基金项目:国家重点研发计划“智能电网技术与装备”专项“电力物联网关键技术”项目(2020YFB0905900)、国家重点研发计划“重大科学仪器设备开发”项目(2016YFF0102200)、国家自然科学基金(51977153, 51977161, 51577046)、中央高校基本科研业务费专项资金(2042021kf0233)、国家自然科学基金重点项目(51637004)、装备预先研究重点项目(41402040301)、湖北省重点研发计划项目(2021BEA162)、武汉市局科技计划项目(20201G01)资助

换器产生破坏性伤害,目前电力电子变换器配备有标准保护电路进行短路故障快速保护。IGBT 开路故障(open circuit fault, OCF)不影响电路一段时间内的正常运行,但会增大元件的电流应力,导致二次故障^[6],本文主要针对 DAB 变换器的 IGBT 开路故障进行诊断。

开路故障诊断方法主要分为基于模型^[7]和基于数据驱动的方法^[8]。前者需要根据电路拓扑和元件特性建立精确的数学模型,目前 DAB 变换器的故障诊断主要采用基于模型的方法^[9-10]。文献[9]和[10]通过对 DAB 变换器建模,分析各 IGBT 开路故障电路波形来确定故障诊断策略。但对于 DAB 变换器等具有对称结构的拓扑,IGBT 之间存在串扰和噪声导致提取的原始监测信号产生失真,难以建立准确的数学模型^[11]。基于数据驱动的方法不用建立数学模型,通过数据挖掘技术结合各种机器学习算法学习各故障类型与样本之间的对应关系。支持向量机(support vector machine, SVM)^[12]、反向传播神经网络^[13]和极限学习机等算法已广泛用于故障诊断中。但此类浅层学习无法深入挖掘故障类别与数据之间的复杂联系,故障诊断准确率较低。

深度学习模型具有强大的泛化能力,可逐层发掘故障特征与所属故障类别之间的对应关系,更适用于故障诊断。文献[14]搭建一维深度卷积神经网络进行故障诊断,但该网络的参数较多,不易调节。文献[15]采用深度信念网络(deep belief network, DBN)在输入故障样本情况下进行故障诊断,相较于卷积神经网络具有较少的超参数。研究表明^[16]DBN 性能与网络超参数设置有关,其中隐藏层单元数对 DBN 性能影响最大,需要对该参数进行优化。多数研究通过经验或反复实验确定相对较优的网络参数^[17],然而该方法需进行大量实验,参数较多的情况下较难进行协同调参。本文采用优化算法对所需优化的参数进行寻优,确定最佳网络参数。

在求解参数优化问题时,很容易陷入局部最优解,群智能优化方法简单、灵活和高效,通过引入随机性实现了全局最优问题。Yang^[18]在 2012 提出了花授粉算法(flower pollination algorithm, FPA),模仿自然界中花授粉的方式提出优化算法,有效解决了收敛问题。但该方法在处理复杂工程问题时,存在计算时间慢、精度低等问题。Mirjalili 等^[19]在 2016 年提出了鲸鱼优化算法(whale optimization algorithm, WOA),通过模仿鲸鱼觅食方式提出了鲸鱼寻找食物源的优化算法,该算法全局搜索和局部寻优能力较强,有效解决了函数寻优问题,但对一些复杂数学函数寻优时存在局部最优问题。每种优化算法都存在不足,对不同的工程问题需要用不同的优化算法并且进行相应改进。本文采用麻雀搜索算法(sparrow search algorithm, SSA)^[20]优化 DBN 的隐藏层单元数,相较遗传算法^[21](genetic algorithm, GA)等具有搜索能力

强、稳定性好及收敛精度高的优点。

综上所述,本文提出了基于莱维飞行麻雀搜索算法(Levy sparrow search algorithm, LSSA)优化 DBN 的 DAB 变换器开路故障诊断方法。首先,使用莱维飞行策略对 SSA 进行改进,提高算法的收敛速度和全局优化能力。其次,利用 LSSA 搜索 DBN 最佳隐藏层单元数,通过比较本算法与其他算法的迭代收敛次数和最佳适应度值,说明本算法具有较强的全局搜索能力。最后,使用 LSSA 搜索得到的最佳隐藏层单元数构建 DBN 故障诊断模型进行 IGBT 的开路故障诊断,实验结果表明本文构建的故障诊断模型相较于其他算法具有较好的诊断精度和稳定性。

1 DAB 变换器的电路拓扑及故障模式

本文以单相 DAB 变换器为研究对象,对单个 IGBT 开路故障情况进行诊断,电路原理如图 1 所示。




图 1 DAB 变换器的拓扑结构

Fig. 1 The topology of DAB convertor

DAB 变换器由原副边对称的两个全桥电路组成,采用移相策略进行控制。移相控制策略主要有 3 种,分别为单移相控制(single phase shift, SPS)控制、扩展型移相控制(extended phase shift, EPS)、和三重移相(triple phase shift, TPS)控制。

每种控制方式中,各功率开关器件的导通占空比为 50% 不变,且斜对角方向的两个功率开关器件总是同时导通,即 S_1 和 S_4 总是同时导通。选择变压器漏感电流 i_{Lr} 为故障诊断检测信号,由于 DAB 变换器的对称性,当斜对角方向的功率开关器件发生故障时,DAB 变换器的变压器漏感电流 i_{Lr} 波形表现相同,因此将斜对角方向的开关器件故障归为同一种故障类别,即 S_1 和 S_4 、 S_2 和 S_3 、 Q_1 和 Q_4 与 Q_2 和 Q_3 分别为同一种故障类别,电路共有包括正常情况在内的 5 种故障类别。

2 DAB 变换器开路故障诊断

2.1 深度信念网络

DBN 是一种深度神经网络^[22],网络由两部分组成。

第1部分是多层受限玻尔兹曼机(restricted boltzmann machine, RBM),可对网络进行无监督逐层预训练,具有强大的特征提取能力。第2部分是前馈反向传播网络,通过在DBN顶层添加分类器,对RBM参数进行监督微调,使堆叠的网络更加精细。图2所示为本文采用具有两层RBM结构的DBN。




图2 两层DBN结构

Fig. 2 Two-layer DBN structure

输入层输入采集的故障样本,输出层输出DAB变换器5种故障模式。RBM1中输入层为可视层 $\mathbf{v}$,由 n 个可视单元组成,输出层为隐藏层 $\mathbf{h}$,由 m 个隐藏单元组成, $\mathbf{v} \in \{0,1\}^n, \mathbf{h} \in \{0,1\}^m$ 表示未激活状态,1表示激活状态。RBM2中输入层为RBM1的输出层。RBM是基于能量的模型,能量函数 $E(\mathbf{v}, \mathbf{h} | \boldsymbol{\theta})$ 定义如下:

$$E(\mathbf{v}, \mathbf{h} | \boldsymbol{\theta}) = - \sum_{i=1}^n \alpha_i v_i - \sum_{j=1}^m \beta_j h_j - \sum_{i=1}^n \sum_{j=1}^m v_i w_{ij} h_j \quad (1)$$

其中, $\boldsymbol{\theta} = [\alpha_i, \beta_j, w_{ij}]$ 是每个RBM的参数, α_i 和 β_j 是 v_i 和 h_j 的偏置, w_{ij} 是连接 v_i 和 h_j 的权重。同一个RBM的可视层和隐藏层的联合概率分布计算公式为:

$$P(\mathbf{v}, \mathbf{h} | \boldsymbol{\theta}) = \frac{1}{Z(\boldsymbol{\theta})} \exp(-E(\mathbf{v}, \mathbf{h} | \boldsymbol{\theta})) \quad (2)$$

其中, Z 是可视层和隐藏层向量相加的归一化系数:

$$Z(\boldsymbol{\theta}) = \sum_{\mathbf{v}} \sum_{\mathbf{h}} \exp(-E(\mathbf{v}, \mathbf{h} | \boldsymbol{\theta})) \quad (3)$$

通过式(2)可以得到输入层向量 $\mathbf{v}$ 的独立分布概率:

$$P(\mathbf{v} | \boldsymbol{\theta}) = \sum_{\mathbf{h}} P(\mathbf{v}, \mathbf{h}) = \frac{1}{Z} \sum_{\mathbf{h}} \exp(-E(\mathbf{v}, \mathbf{h})) \quad (4)$$

在确定可视层向量或隐藏层向量后,可得到另一隐藏层或可视层的分布概率。利用上述关系,可以使用激活函数 $\text{sigmoid}(x) = 1/(e^{-x})$ 分别单独计算隐藏层第 j 个单元和可视层第 i 个单元被激活的概率:

$$P(h_j = 1 | \mathbf{v}; \boldsymbol{\theta}) = \text{sigmoid}(\beta_j + \sum_{i=1}^n w_{ij} v_i) \quad (5)$$

$$P(v_i = 1 | \mathbf{h}; \boldsymbol{\theta}) = \text{sigmoid}(\alpha_i + \sum_{j=1}^m w_{ij} h_j) \quad (6)$$

在给定训练数据的情况下,式(4)的概率可通过微调相关参数使可视层输出更加接近真实值。训练向量的概率与向量能量有关,能量与 $\boldsymbol{\theta}$ 有关,可以通过调整 $\boldsymbol{\theta}$ 来

调整能量。根据最大似然估计原理对 $\boldsymbol{\theta}$ 进行估计:

$$\begin{cases} \frac{\partial \ln P(\mathbf{v}; \boldsymbol{\theta})}{\partial w_{ij}} = \langle v_i h_j \rangle_{p(\mathbf{h} | \mathbf{v}; \boldsymbol{\theta})} - \langle v_i h_j \rangle_{\text{recon}} \\ \frac{\partial \ln P(\mathbf{v}; \boldsymbol{\theta})}{\partial \alpha_i} = \langle v_i \rangle_{p(\mathbf{h} | \mathbf{v}; \boldsymbol{\theta})} - \langle h_j \rangle_{\text{recon}} \\ \frac{\partial \ln P(\mathbf{v}; \boldsymbol{\theta})}{\partial \beta_j} = \langle h_j \rangle_{p(\mathbf{h} | \mathbf{v}; \boldsymbol{\theta})} - \langle h_j \rangle_{\text{recon}} \end{cases} \quad (7)$$

其中, $\langle \cdot \rangle_{p(\mathbf{h} | \mathbf{v}; \boldsymbol{\theta})}$ 为训练数据的分布期望, $\langle \cdot \rangle_{\text{recon}}$ 为重构模型的分布期望。无偏的 $\langle \cdot \rangle_{\text{recon}}$ 较难获得,因此采用类似于对比差异的梯度函数,将 $\langle \cdot \rangle_{\text{recon}}$ 由 k 次吉布斯采样代替,上述模型参数的更新公式修改如下:

$$\begin{cases} \Delta w_{ij} = \rho (\langle v_i h_j \rangle_{p(\mathbf{h} | \mathbf{v}; \boldsymbol{\theta})} - \langle v_i h_j \rangle_k) \\ \Delta \beta_j = \rho (\langle h_j \rangle_{p(\mathbf{h} | \mathbf{v}; \boldsymbol{\theta})} - \langle h_j \rangle_k) \\ \Delta \alpha_i = \rho (\langle v_i \rangle_{p(\mathbf{h} | \mathbf{v}; \boldsymbol{\theta})} - \langle v_i \rangle_k) \end{cases} \quad (8)$$

其中, $\rho \in (0,1)$ 是学习率。当各参数训练数据分布于重构模型的分布期望最小时,DBN学习结束。

2.2 LSSA 优化

1) 麻雀搜索算法原理

本文采用LSSA对DBN隐藏层单元数进行优化。SSA是一种群体优化算法,由薛建凯等于2020年提出,原理为麻雀的觅食和反捕食行为。它不依赖待解决的问题的应用背景,不受目标函数的限制,可实现全局优化,搜索能力较强。其生物学特性如下:

(1) 麻雀种群由发现者和跟随者构成。发现者为整个种群寻找食物,跟随者跟随发现者获取食物。二者身份可互换以获得更好的食物来源,但总数不变。

(2) 种群的觅食行为与种群能量储备有关,发现者能量储备较多,跟随者较低。个体适应度值与能量储备有关,个体能量越大,适应度值越好。当能量低于某一值,发现者需要去别处觅食以获得更多能量。

(3) 在种群觅食过程中,跟随者会寻找能量储备最多的发现者来获得食物。部分跟随者为提高觅食量,会长期监视发现者以时刻准备争夺食物。

(4) 种群中某个体发现捕食者时,会立刻发出警报。群体边缘的麻雀迅速移动到安全区域,中心位置的麻雀随机移动靠近其他个体。当警报值超过种群安全阈值时,发现者引导跟随者到其他安全区域觅食。

2) 麻雀搜索算法的数学模型

根据上述规则可以建立麻雀种群觅食行为的数学模型。有 s 个麻雀的种群可以表示为:

$$\mathbf{X} = \begin{bmatrix} X_{1,1} & X_{1,2} & \cdots & X_{1,\delta} \\ X_{2,1} & X_{2,2} & \cdots & X_{2,\delta} \\ \vdots & \vdots & \ddots & \vdots \\ X_{s,1} & X_{s,2} & \cdots & X_{s,\delta} \end{bmatrix} \quad (9)$$

δ 表示待优化问题变量的维数。种群中麻雀的适应度向量可以表示为:

$$\mathbf{F}(\mathbf{X}) = \begin{bmatrix} f_v([X_{1,1}, X_{1,2}, \dots, X_{1,\delta}]) \\ f_v([X_{2,1}, X_{2,2}, \dots, X_{2,\delta}]) \\ \vdots \\ f_v([X_{s,1}, X_{s,2}, \dots, X_{s,\delta}]) \end{bmatrix} \quad (10)$$

f_v 表示适应度函数, 本文设置 f_v 为每次迭代过程中训练集故障类别和预测故障类别之差的均方根值, 表达式为:

$$f_v = \frac{1}{N} \sum_{i=1}^N |y_{pre} - y_{true}|^2 \quad (11)$$

y_{pre} 为每次迭代中 DBN 的预测故障类别, y_{true} 为每次迭代中实际故障类别, N 为训练集样本个数。寻找食物的过程中, 发现者相较跟随者具有更大的觅食范围, 具有较好的适应度值, 会最先找到食物。由规则(1)和(4)可知, 发现者的位置在每次迭代中更新为:

$$X_{l,\varphi}^{v+1} = \begin{cases} X_{l,\varphi}^v \times \exp(-\frac{l}{\xi \times C_{iteration_max}}), R < ST \\ X_{l,\varphi}^v + Q \cdot \mathbf{L}, R \geq ST \end{cases} \quad (12)$$

其中, v 为当前迭代次数, $C_{iteration_max}$ 为最大迭代次数。 $X_{l,\varphi}^v$ 为第 v 次迭代第 l 只麻雀在第 φ 维的位置, $l \in [1, 2, \dots, s]$, $\varphi \in [1, 2, \dots, \delta]$ 。 ξ 是 $(0, 1]$ 内的随机数, Q 是服从正态分布的随机数, $\mathbf{L}$ 是 $[1 \times \delta]$ 的单位向量。 $R \in [0, 1]$ 是当前警报值, $ST \in [0.5, 1]$ 是安全阈值。当 $R < ST$ 时, 发现者能够在没有捕食者的情况下广泛觅食, $R \geq ST$ 时出现捕食者, 侦察者发出警报, 所有麻雀应迅速飞到其他安全区域。由规则(2)和(3)可得, 跟随者的位置更新公式为:

$$X_{l,\varphi}^{v+1} = \begin{cases} Q \cdot \exp(\frac{X_{worst}^v - X_{l,\varphi}^v}{l^2}), l > \frac{s}{2} \\ X_p^v + |X_{l,\varphi}^v - X_p^v| \cdot \mathbf{A}^+ \cdot \mathbf{L}, l \leq \frac{s}{2} \end{cases} \quad (13)$$

其中, X_p 表示当前发现者的最佳位置, X_{worst} 表示当前全局最差位置。 $\mathbf{A}$ 是一个 $1 \times \delta$ 维向量, 每个元素随机分配为 1 或 -1, 且 $\mathbf{A}^+ = \mathbf{A}(\mathbf{A}\mathbf{A}^T)^{-1}$ 。当 $l > s/2$ 时, 表明适应度较差的跟随者得不到食物, 会转移其他地方觅食, 当 $l \leq s/2$ 时, 跟随者会在 X_p 周围觅食。

为躲避捕食者, 在种群中随机选择 10% ~ 20% 的麻雀作为侦察兵, 遇到危险时发出警报声。当捕食者出现时, 根据规则(4), 种群中个体的行为表示如下:

$$X_{l,\varphi}^{v+1} = \begin{cases} X_{best}^v + \beta \times |X_{l,\varphi}^v - X_{best}^v|, f_v(X_{l,\varphi}^v) > f_{v_best} \\ X_{l,\varphi}^v + \zeta \times \frac{|X_{l,\varphi}^v - X_{best}^v|}{(f_v(X_{l,\varphi}^v) - f_{v_worst}) + \varepsilon}, f_v(X_{l,\varphi}^v) = f_{v_best} \end{cases} \quad (14)$$

其中, X_{best}^v 表示当前全局最佳位置, 为最佳隐藏层单

元数的组合。 β 是均值为 0, 方差为 1 的正态分布步长控制随机数。 $\xi \in [-1, 1]$ 为群体中个体移动方向的随机数。 $f_v(X_{l,\varphi}^v)$ 是当前麻雀个体的适应度值, f_{v_best} 和 f_{v_worst} 分别是当前全局最优和最差适应度值。 $f_v(X_{l,\varphi}^v) > f_{v_best}$ 时, 麻雀 v 位于种群边缘, 易受捕食者攻击。 $f_v(X_{l,\varphi}^v) = f_{v_best}$ 时, 处于群体中心的个体意识到危险并开始向其他个体靠拢。 ε 是非常小的常数, 用来防止分母为 0。随后根据计算的最佳适应度值和最佳全局位置进行下一次迭代。

3) 莱维飞行

莱维飞行最早由 Levy 提出的, 然后由 Benoit Mandelbrot 对其进行详细描述^[23]。莱维飞行使用随机步长描绘 Levy 分布, 大量研究表明, 许多动物和昆虫的行为表现是莱维飞行的经典特征。如图 3 是关于莱维飞行位置更新的模拟图像, 由图可以看出莱维飞行过程中小步长的短距离飞行与偶尔大步长的长距离飞行相互交替, 具有较大的搜索范围。




图3 莱维飞行轨迹

Fig. 3 Levy's flight path

该图像根据位置更新公式记录所有粒子位置的更新信息。位置更新公式表示为:

$$x_i^{t+1} = x_i^t + \alpha \oplus Levy \quad (15)$$

其中, α 为步长因子(人为设定参数), $Levy$ 决定行进方向和步长, $\oplus$ 算符表示点对点的乘法, 当前的位置由之前位置更新概率决定。

式(15)中的 $Levy$ 随机分布通常以简化形式出现, 如:

$$Levy \sim |s|^{-\lambda}, 1 < \lambda \leq 3 \quad (16)$$

其中, s 为随机的 $Levy$ 步长, 在 Mantegna 提出的算法中, 随机步长 s 可以用式(17)进行描述, 其数学公式为:

$$s = \frac{\mu}{|v|^{1/\beta}} \quad (17)$$

其中, 参数 $\beta = 1.5$, $\mu = N(0, \sigma_\mu^2)$ 和 $v = N(0, \sigma_\mu^2)$ 都

表示 gamma 函数。式(17)中参数的方差数学公式为:

$$\sigma_{\mu} = \left[\frac{\Gamma(1+\beta) \times \sin(\pi \times \beta/2)}{\Gamma[(1+\beta)/2] \times \beta \times 2^{(\beta-1)/2}} \right]^{1/\beta}, \sigma_v = 1 \quad (18)$$

4) 基于莱维飞行的麻雀搜索算法

麻雀优化算法可以简单、高效的解决低维单模优化问题。然而在处理高维和复杂问题时,传统 SSA 得到的解并不十分理想,而且运算时间长。为了提高 SSA 的全局搜索能力和局部探索能力,本文提出了一种改进的莱维飞行麻雀搜索化算法。Levy 飞行可以最大限度的实现搜索域的多样化,能够保证算法高效搜索食物源的位置,实现局部最优^[24]。这一发现表明,莱维飞行有助于 SSA 获得更好的寻优结果,减少运算时间,因此对麻雀的位置更新公式做出优化,将式(14)结合式(16)进行改进,用如下数学公式表达:

$$X_{l,\varphi}^{v+1} = \begin{cases} X_{best}^v + |X_{l,\varphi}^v - X_{best}^v| \times \text{Levy}_v f_v(X_{l,\varphi}^v) > f_{v_best} \\ X_{l,\varphi}^v + \zeta \times \frac{|X_{l,\varphi}^v - X_{best}^v|}{(f_v(X_{l,\varphi}^v) - f_{v_worst}) + \varepsilon} f_v(X_{l,\varphi}^v) = f_{v_best} \end{cases} \quad (19)$$

莱维飞行能够大幅提高 SSA 的全局搜索能力从而避免进入局部最优值。这种方法不仅提高了 SSA 的搜索强度,也降低了算法的运算时间。通过优化算法保证该算法能够找到最优值并且避免陷入局部最优,通过增强多样性使该算法具有更好的全局搜索能力。

LSSA-DBN 的算法流程如图 4 所示。首先,输入故障样本并将其划分为训练集和测试集,初始化 DBN 和 LSSA 的参数并设置适应度函数 f_v 。然后,计算当前种群的适应度值,并根据式(12)、(13)和(14)分别计算当前种群发现者、跟随者和侦察者的位置。根据改进的式(19)更新侦察者的位置,以及当前最佳位置 X_p 和最佳适应度值 f_{v_best} 。重复此过程直至达到迭代次数,得到种群的最佳位置 H_1_BEST 和 H_2_BEST 。 H_1_BEST 和 H_2_BEST 分别为 DBN 中 RBM1 和 RBM2 的最佳隐藏层单元数。最后,将该值输入到 DBN 中进行故障样本的训练和分类。

3 实验结果

3.1 系统仿真实验

为验证本文方法的有效性和准确性,利用 RT-LAB 搭建 DAB 变换器半实物仿真系统,采用 OP5700 实时模拟器模拟单相 DAB 变换器,将模拟器中 DAC 输出的 DAB 变换器输出电压输出到 PZ-DSP28335-L 进行 EPS 和电压单闭环控制^[25],由 OP5700 模拟器的数字输入电路接收控制信号,实验系统如图 5 所示。




图 4 LSSA-DBN 算法流程

Fig. 4 LSSA-DBN flow chart




图 5 RT-LAB 实验系统

Fig. 5 RT-LAB experimental system

输入电压 U_1 为 100 V,输出电压 U_2 为 60 V,输入电容 C_1 为 470 μF ,输出电容 C_2 为 2 000 μF ,输出电阻 R_0 为 20 Ω 。IGBT 阻尼电容 C_f 为 50 nF,变压器变比 N 为 1,开关频率 f 为 10 kHz,变压器漏感 L_r 为 100 μH 。采样频率 f_s 为 100 kHz。收集正常状态和各 IGBT 故障的 i_{Lr} ,为使各类故障样本数一致,对正常状态收集 2 次样本。即 5 种电路故障状态,每个状态 200 个样本,共 1 000 个样本,每个样本 1 000 个点。每种故障状态下 i_{Lr} 波形如图 6 所示,图中横坐标表示每个样本中的采样点数,纵坐标表示 i_{Lr} 的大小。




图 6 各种故障状态下 i_{Lr} 波形

Fig. 6 i_{Lr} under different fault conditions

3.2 标准函数的实验与分析

本文选取多种标准函数作为测试函数来衡量元启发式算法的性能。测试函数公式如表 1 所示,利用不同函数的数学特性,从不同角度测试 LSSA 的性能。测试函数主要分为两类:高维单模态测试函数、高维多模态测试函数(如图 7 所示)。表 1 中 $F_1 \sim F_4$ 为高维单峰值测试函数, $F_5 \sim F_6$ 为高维多峰值测试函数,域值表示函数的搜索域。

表 1 标准测试函数

Table 1 Standard test function


标准函数	维数	域值	最小值
$F_1(x) = \sum_{i=1}^n x_i^2$	20	$[-100, 100]$	0
$F_2(x) = \sum_{i=1}^n x_i + \prod_{i=1}^n x_i $	20	$[-10, 10]$	0
$F_3(x) = -20 \exp(-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}) - \exp(\frac{1}{n} \sum_{i=1}^n \cos 2\pi x_i) + 20 + e$	20	$[-32, 32]$	0
$F_4(x) = \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos(\frac{x_i}{\sqrt{i}}) + 1$	20	$[-600, 600]$	0
$F_5(x) = 4x_1^2 - 2.1x_1^4 + \frac{1}{3}x_1^6 + x_1x_2 - 4x_2^2 + 4x_2^4$	2	$[-5.12, 5.12]$	-1
$F_6(x) = 0.1 \sin^2(3\pi x_1) + \sum_{i=1}^{29} (x_i - 1)^2 [1 + \sin^2(3\pi x_i)] + (x_{30} - 1)^2 [1 + \sin^2(2\pi x_{30})] + \sum_{i=1}^{30} u(x_i, 5, 100, 4)$	2	$[-100, 100]$	0

通过表 2 可以明显看到莱维飞行麻雀搜索算法在初始种群数量 $N = 20$ 时,在最优值的搜索中优于 SSA 算法在种群数量为 $N = 20$ 和 $N = 100$ 时,说明改进后的麻雀算法在减少初始种群的情况下,具有更好的寻优结果,保证了算法的寻优能力。由以上分析可知,改进的麻雀搜索算法提高了算法的寻优能力,将其应用在 DAB 变换器故障诊断领域可以有效解决其诊断精度低,鲁棒性差等问题。


表 2 SSA 与 LSSA 的最优值

Table 2 The optimal value of SSA and LSSA


函数名	SSA ($N=20$)	SSA ($N=100$)	LSSA ($N=20$)
F_1	3.12×10^{-3}	1.76×10^{-6}	1.1781×10^{-15}
F_2	2.27×10^{-3}	3.61×10^{-5}	1.9008×10^{-7}
F_3	1.92×10^{-2}	1.86×10^{-3}	2.1186×10^{-6}
F_4	4.29×10^{-2}	3.98×10^{-6}	3.7026×10^{-12}
F_5	-0.926 9	-0.990 0	-0.99
F_6	3.12×10^{-3}	4.12×10^{-7}	5.2767×10^{-15}



(a) 单峰值函数
(a) Single peak function



(b) 多峰值函数
(b) Multi-peak function



(c) 多峰值函数
(c) Multi-peak function

图 7 标准测试函数效果图

Fig. 7 Standard test function renderings

3.3 故障诊断结果及各种方法对比

将数据集输入到 DBN 中,随机选取样本的 70%作为训练集,剩下的 30%作为测试集进行实验。设置 DBN 的隐藏层为两层,整体参数设置如表 3 所示。

表 3 DBN 参数设置

Table 3 Parameter settings of DBN			
参数设置	数值	参数设置	数值
输入层单元数	100	学习率	0.1
输出层单元数	5	动量	0.8
隐藏层数	2	批大小	100
隐藏层 1 单元数	H_1	批次	50
隐藏层 2 单元数	H_2	激活函数	Sigmoid

使用 LSSA 对 DBN 隐藏层的单元数 H_1 和 H_2 进行寻优,记每次迭代过程训练集真实和预测故障类别之差的均方根值为优化函数的适应度值。为显示本文所提方法的寻优能力和故障诊断效果,将 LSSA-DBN 与 SSA-DBN、GWO-DBN、GA-DBN、LSSA-SVM 和 GWO-SVM 进行对

比,并设置相同的迭代误差函数,6 种方法的迭代曲线如图 8 所示。




图 8 迭代误差曲线

Fig. 8 The iteration error curve

LSSA-DBN 方法在第 11 次迭代时收敛,最终迭代误差值为 0.003 3,相较于 SSA-DBN、GWO-DBN、GA-DBN、LSSA-SVM 和 GWO-SVM 具有较快的迭代收敛速度和最小的迭代误差。最终的寻优结果为隐藏层单元数 H_1 和 H_2 分别为 56 和 32,在该参数设置下 DBN 的测试准确度可达 99.67%。将上述 6 种方法进行 50 次重复实验,各个方法的准确度结果如图 9 所示,可以看出 LSSA-DBN 方法具有较高的故障诊断稳定性和诊断准确率。




图 9 故障诊断箱型图

Fig. 9 Box diagram of fault diagnosis

为显示 LSSA-DBN 方法对各个故障类别的诊断状况,使用混淆矩阵进行观察,混淆矩阵如图 10 所示。其中横纵坐标中“0”、“1”、“2”、“3”和“4”分别表示 DAB 变换器的正常状态、 S_1/S_4 故障、 S_2/S_3 故障、 Q_1/Q_4 和 Q_2/Q_3 故障状态。主对角线表示 LSSA-DBN 对各个故障类别的诊断准确率,可以看出 LSSA-DBN 对正常状态、 S_1/S_4 故障、 S_2/S_3 故障的诊断准确度可达 100%, Q_1/Q_4 和 Q_2/Q_3 故障的准确度也在 98% 以上,具有较高的诊断

准确度。




图 10 故障诊断混淆矩阵

Fig. 10 Confusion matrix of fault diagnosis

4 结 论

本文提出基于莱维飞行麻雀搜索算法优化深度信念网络的 DAB 变换器 IGBT 开路故障诊断方法。针对 DAB 变换器中 IGBT 开路故障诊断精度较低的问题,使用莱维飞行策略改进 SSA 提升其优化能力,并利用改进的 SSA 优化 DBN 隐藏层单元数,进而构建 LSSA-DBN 故障诊断模型,解决手动实验或经验设置确定隐藏层单元数的问题。通过在 RT-LAB 仿真平台实验验证,本文提出的算法与 SSA-DBN、GWO-DBN、GA-DBN、LSSA-SVM 和 GWO-SVM 相比较,具有较好的优化能力,可以快速寻找出最佳隐藏层单元数,且使用最佳隐藏层单元数建立的 LSSA-DBN 故障诊断模型有较好的故障诊断精度和稳定性,诊断精度达到 99%。

参考文献

[1] WEN H Q, LI J L, SHI H C, et al. Fault diagnosis and tolerant control of dual-active-bridge converter with triple-phase shift control for bidirectional EV charging systems[J]. IEEE Transactions on Transportation Electrification, 2021, 7(1): 287-303.

[2] 孙凯, 陈欢, 吴红飞. 面向储能系统应用的隔离型双向 DC-DC 变换器分析方法与控制技术综述[J]. 电工电能新技术, 2019, 38(8): 1-9.

SUN K, CHEN H, WU H F. A review of analysis method and control technology for isolated bidirectional DC-DC converter used in energy storage systems[J]. Advanced Technology of Electrical Engineering and Energy, 2019, 38(8): 1-9.

[3] 孙孝峰, 张绘欣, 张涵, 等. 一种用于电-氢多能互补型微电网的双有源桥集成 Boost 拓扑及其控制[J]. 电工技术学报, 2021, 36(10): 2092-2104.

SUN X F, ZHANG H X, ZHANG H, et al. Topology

and control strategy of dual active bridge integrated boost circuit for electro-hydrogen multi-energy complementary microgrid[J]. Transactions of China Electrotechnical Society, 2021, 36(10): 2092-2104.

[4] 赵彪, 安峰, 宋强, 等. 双有源桥式直流变压器发展与应用[J]. 中国电机工程学报, 2021, 41(1): 288-298.

ZHAO B, AN F, SONG Q, et al. Development and application of DC transformer based on dual-active-bridge[J]. Proceedings of the CSEE, 2021, 41(1): 288-298.

[5] YANG S Y, XIANG D W, 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.

[6] 陈勇, 刘志龙, 陈章勇. 基于电流矢量特征分析的逆变器开路故障快速诊断与定位方法[J]. 电工技术学报, 2018, 33(4): 883-891.

CHEN Y, LIU ZH L, CHEN ZH Y. Fast diagnosis and location method of open-circuit fault in inverter based on current vector character analysis[J]. Transactions of China Electrotechnical Society, 2018, 33(4): 883-891.

[7] SCHMID M, GEBAUER E, HANZL C, et al. Active model-based fault diagnosis in reconfigurable battery systems[J]. IEEE Transactions on Power Electronics, 2021, 36(3): 2584-2597.

[8] XIA Y, XU Y, GOU B. A data-driven method for IGBT open-circuit fault diagnosis based on hybrid ensemble learning and sliding-window classification[J]. IEEE Transactions on Industrial Informatics, 2020, 16(8): 5223-33.

[9] AIRABELLA A M, OGGIER G G, PIRIS-BOTALLA L E, et al. Semi-conductors faults analysis in dual active bridge DC-DC converter[J]. IET Power Electron, 2016, 9(6): 1103-1110.

[10] ZHENG M K, WEN H Q, SHI H C, et al. Open-circuit fault diagnosis of dual active bridge DC-DC converter with extended-phase-shift control[J]. IEEE Access, 2019, 7: 23752-23765.

[11] 于生宝, 何建龙, 王睿家, 等. 基于小波包分析和概率神经网络的电磁法三电平变换器故障诊断方法[J]. 电工技术学报, 2016, 31(17): 102-112.

YU SH B, HE J L, WANG R J, et al. Fault diagnosis of electromagnetic three-level inverter based on wavelet packet analysis and probabilistic neural networks[J]. Transactions of China Electro-technical Society, 2016, 31(17): 102-112.

[12] 朱哈娜, 刘慧明. 基于改进 VMD 与 GS_SVM 的轴承故障诊断[J]. 电子测量技术, 2020, 43(21): 71-76.

ZHU H N, LIU H M. Bearing fault diagnosis based on

- improved VMD and GS _ SVM [J]. Electronic Measurement Technology, 2020, 43(21): 71-76.
- [13] LU Q D, YANG R, ZHONG M Y, 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.
- [14] 孙曙光, 李勤, 杜太行, 等. 基于一维卷积神经网络的低压万能式断路器附件故障诊断[J]. 电工技术学报, 2020, 35(12): 2562-2573.
- SUN SH G, LI Q, DU T H, et al. Fault diagnosis of accessories for the low voltage conventional circuit breaker based on one dimensional convolutional neural network [J]. Transactions of China Electrotechnical Society, 2020, 35(12): 2562-2573.
- [15] 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.
- ZHANG CH L, HE Y G, DU B L. Analog circuit incipient fault diagnosis method based on DBN feature extraction[J]. Chinese Journal of Scientific Instrument, 2019, 40(10): 112-119.
- [16] COATES A, NG A Y, LEE H. An analysis of single-layer networks in unsupervised feature learning [J]. Journal of Machine Learning Research, 2011, 15: 215-223.
- [17] 赵光权, 姜泽东, 胡聪, 等. 基于小波包能量熵和DBN的轴承故障诊断[J]. 电子测量与仪器学报, 2019, 33(2): 32-38.
- ZHAO G Q, JIANG Z D, HU C, et al. Bearing fault diagnosis based on wavelet packet energy entropy on DBN[J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(2): 32-38.
- [18] YANG X S. Flower pollination algorithm for global optimization [C]. International Conference on Unconventional Computation and Natural Computation, 2012: 240-249.
- [19] MIRJALILI S, LEWIS A. The whale optimization algorithm[J]. Advances in Engineering Software, 2016, 95: 51-67.
- [20] XUE J K, SHEN B. A novel swarm intelligence optimization approach: Sparrow search algorithm [J]. System Science & Control Engineering, 2020, 8(1): 22-34.
- [21] 刘伟, 李有红, 王赞, 等. 无线电能传输系统多目标遗传算法参数优化[J]. 国外电子测量技术, 2020, 39(6): 86-90.
- LIU W, LI Y H, WANG Y, et al. Parameter optimization of multi-objective genetic algorithm wireless power transfer system [J]. Foreign Electronic Measurement Technology, 2020, 39(6): 86-90.
- [22] ZHONG T, QU J F, FANG X Y, et al. The intermittent fault diagnosis of analog circuits based on EEMD-DBN[J]. Neurocomputing, 2021, 436: 74-91.
- [23] DOU R, DUAN H. Lévy flight based pigeon-inspired optimization for control parameters optimization in automatic carrier landing system[J]. Aerospace Science & Technology, 2017, 61: 11-20.
- [24] 邢致恺, 贾鹤鸣, 宋文龙. 基于莱维飞行樽海鞘群优化算法的多阈值图像分割[J]. 自动化学报, 2021, 47(2): 363-377.
- XING ZH K, JIA H M, SONG W L. Levy trajectory-based salp swarm algorithm for multilevel thresholding image segmentation[J]. Acta Automatica Sinica, 2021, 47(2): 363-377.
- [25] HOU N, SONG W S, WU M Y. Minimum-current-stress scheme of dual active bridge DC-DC converter with unified phase-shift control [J]. IEEE Transactions on Power Electronics, 2016, 31(12): 8552-61.

作者简介



赵莹莹, 2020 年于吉林大学获得学士学位, 现为武汉大学电气与自动化学院硕士研究生, 主要研究方向为电力电子变换器故障诊断和深度学习。

E-mail: 2020202070009@whu.edu.cn

Zhao Yingying received her B. Sc. degree from Jilin University in 2020. Now she is a M. Sc. candidate at Wuhan University. Her main research interests include fault diagnosis of power converter and deep learning.



何怡刚 (通信作者), 1992 年于西安交通大学获得博士学位, 现为武汉大学教授, 主要研究方向为混合信号电路故障诊断、电子设备可靠性和通信信道建模与监测等。

E-mail: 18655136887@163.com

He Yigang (Corresponding author) received his Ph. D. degree from Xi'an Jiaotong University in 1992. Now he is a professor at Wuhan University. His main research interests include mixed-signal circuit fault diagnosis, electronic equipment reliability, and communication channel modeling and monitoring.