

基于布谷鸟搜索算法和 DBN 模型的 变压器故障识别

刘展程¹, 王爽^{1,2}, 唐波^{1,2}

(1. 三峡大学电气与新能源学院, 湖北宜昌 443002; 2. 三峡大学湖北省输电线路工程技术研究中心, 湖北宜昌 443002)

摘要:依据油中溶解气体含量特征准确识别变压器故障类型,对变压器的安全运行具有重要意义。考虑深度信念网络(DBN)对样本数据中的特征提取有独特优势,采用 DBN 作为故障识别模型,将变压器油中溶解气体原始数据集直接输入至训练模型,并通过 3 种智能搜索算法对 DBN 中批处理、梯度下降学习率、层神经单元数 3 个重要参数分别进行智能寻优,解决少量原始样本数据直接输入时故障识别率不高的问题。仿真结果表明,采用布谷鸟搜索算法(CS)优化 DBN 模型时比粒子群搜索算法(PSO)和遗传算法搜索(GA)优化的效果更好,CS-DBN 模型的故障总识别率比 GA-DBN 的高 4.2%,比 PSO-DBN 的提高 2.5%,同时进化效率提高 56.2%;CS-DBN 模型的泛化性能也比另 2 种更好。

关键词:油中溶解气体;深度信念网络;故障识别;布谷鸟搜索算法;泛化性能

DOI:10.19781/j.issn.1673-9140.2022.02.001 中图分类号:TM85 文章编号:1673-9140(2022)02-0003-09

Transformer fault identification based on the cuckoo search algorithm and DBN model

LIU Zhancheng¹, WANG Shuang^{1,2}, TANG Bo^{1,2}

(1. College of Electrical Engineering & New Energy, China Three Gorges University, Yichang 443002, China; 2. Hubei Provincial Engineering Technology Research Center for Power Transmission Line, China Three Gorges University, Yichang 443002, China)

Abstract: The fault identification of transformer based on the characteristics of dissolved gas contents in the oil is of great significance to its safe operation. The deep belief network (DBN) is selected as a fault identification model in this paper since it has unique for extracting features from sample data. Firstly, the original data set of dissolved gas in transformer oil is directly deployed as the inputs of the training model, and the DBN is processed through three intelligent search algorithms. Three important parameters of mid-batch processing, gradient descent learning rate, and number of neural units are intelligently optimized to solve the problem of a low fault recognition rate when input raw sample data are limited. It is shown that the performance of the proposed method is better than the particle swarm search (PSO) algorithm and genetic algorithm (GA) search optimization. The total recognition rate of CS-DBN is 4.2% higher than that of GA-DBN, 2.5% higher than PSO-DBN and 56.2% higher in evolution efficiency. It also has a good generalization performance.

Key words: dissolved gas in oil; DBN; fault recognition; CS algorithm; generalization performance

电力变压器是电网的重要设备,准确识别变压器的故障对电力系统的安全运行意义重大。当变压器正常运行时,油箱内的绝缘油和绝缘材料会在电、热等因素的作用下逐渐老化,裂解出少量的氢气、低分子烃类气体以及一氧化碳、二氧化碳等气体,当变压器内部发生过热故障或放电故障时,也会产生这些气体,并在热的作用下迅速析出并积累,使得油中溶解气体的成分和含量及增长速率发生变化^[1-2]。油中溶解气体分析(dissolved gas analysis, DGA)因具有带电检测作业、不受外界电磁场影响、响应速度快等特点而被广泛用于变压器的故障识别和健康状态评估^[3]。常用的根据 DGA 特征气体检测变压器内部故障的方法有 IEC 三比值法^[4]、改良电协研法^[5]、Domenburg 比值法^[6]以及 Duval 比值法^[7]等,这些方法本质上是依据不同气体间的比值,采用编码的方式对故障进行线性分类,但均存在故障编码缺失或分类过于绝对而导致边界附近样本分类效果不佳的问题,影响故障类型识别的准确性。

随着人工智能技术的发展,一系列浅层机器学习方法也被应用到变压器故障分类和识别中,这些方法的应用对分类边界问题做出了改善,但也仍存在一些不足之处。神经网络具有多层网络设计,可以实现任意非线性映射,在分类、识别故障时比线性函数更精准,但训练时容易陷入局部收敛,对新数据的泛化性能较弱^[8-9]。支持向量机^[10]在小样本数据的训练上有突出优势,但它本质是二分类器,对于大量 DGA 数据及多种故障分类的处理效率不高。模糊理论算法^[11]利用较粗糙的模型,就能较好解决多分类边界样本的划分问题,但输出空间划分和隶属度函数选择往往需要依靠个人经验,具有很大主观性和不确定性。灰色关联分析法^[12]不需要考虑样本数量或数据规律性,可以剔除相关性较弱的信息,提高故障分类、识别精度,但同样主观性过强。以上常用的浅层机器学习方法普遍存在学习能力不足、特征提取能力欠缺、主观经验过强等问题。随着大数据分析技术的成熟以及变压器在线监测设备的普及,DGA 样本数据愈发庞大,变压器故障分类愈发细致,传统的机器学习方法难以满足训练效率、故障识别精度和模型泛化能力等要求,因此需要找到更

有效的方法解决上述问题。

文献[13]在 2006 年提出了一种能在海量数据中有效识别、提取样本特征的深度学习模型——深度信念网络(deep belief network, DBN),近年来被多次应用在变压器故障识别的模型训练中;文献[14]采用 DBN 模型与传统机器学习模型作对比,证明训练样本数、DBN 结构中的网络层数和隐层节点数对故障识别精度的影响至关重要;文献[15]采用 9 种无编码 DGA 比值样本训练组合 DBN 模型,结果显示,故障识别率比直接输入样本数据时的更高;文献[16]综合了 IEC、Rogers、Dornenburg 和 Duval 比值 4 种方法,提出了新的气体浓度比值方式,作为 DBN 模型的训练输入,结果表明,新提的比值方式更利于挖掘数据特征信息、提高变压器运行状态识别;文献[17]采用 ReLU 激活函数改进 DBN 模型,并提出一种新的油色谱特征气体无编码比值方式作为训练输入,结果显示,与传统的几种比值输入相比模型的故障诊断精度大大提高。当前,提高 DBN 模型故障识别精度的研究工作大多聚焦于二次处理输入的样本数据,增加数据的规律性以提高样本的质量,少有研究采用原始数据集作为模型输入,并直接优化 DBN 的训练过程和内部结构,从根源上提高故障识别率与模型泛化性能。

布谷鸟搜索(cuckoo search, CS)算法具有在多参数全局寻优、提升泛化性能等方面的突出优势,故本文采用 CS 算法,对 DBN 网络训练过程最关键的批尺寸 bat_size、梯度下降学习率 alpha 以及网络结构最核心的层神经单元数 num 进行智能寻优,进而实现根据输入的不同原始样本数据自动调整 DBN 模型的训练参数,以及自动寻找最合适网络结构,避免结果局部收敛,提升故障识别率和训练模型的泛化性能。

1 深度信念网络

DBN 是由多层受限玻尔兹曼机(restricted boltzmann machines, RBM)组成的神经网络,是一种概率生成模型,在故障分类、识别问题上有突出的性能优势^[18],其训练过程为使用非监督贪婪逐层方法

去预训练获得各层 RBM 权值。

1.1 受限玻尔兹曼机的结构

RBM 是一种具有随机性的生成神经网络结构,是由一层可见层 V 和隐藏层 H 组成的无向图模型,神经元只在层间有连接,在层内无连接,其结构如图 1 所示, w 为层间的连接权重,偏置系数记为 R ,其中可见层 V 神经元的偏置系数为 R_v ,隐藏层 H 神经元的偏置系数为 R_h 。

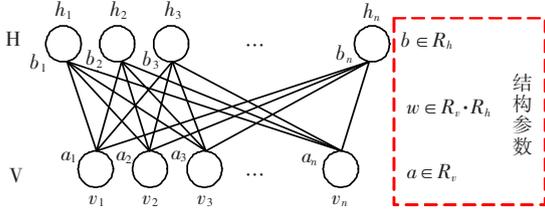


图 1 RBM 结构

Figure 1 RBM structure diagram

RBM 是一个基于能量函数的概率分布模型,若给定状态组 (h, v) ,则 RBM 当前的能量函数^[19]可以表示为

$$E_{\theta}(v, h) = - \sum_{i=1}^{n_v} a_i v_i - \sum_{j=1}^{n_h} b_j h_j - \sum_{i=1}^{n_v} \sum_{j=1}^{n_h} h_j w_{ij} v_i \quad (1)$$

式中 $\theta = \{w_{ij}, a_i, b_j\}$ 为 RBM 的 3 个结构参数集合; v_i 为第 i 个显层神经元的状态; h_j 为第 j 个隐层神经元的状态。

能量函数是描述整个系统状态的一种测度,系统的概率分布越集中,则系统的能量越小,表明系统越稳定。通过能量函数可以定义一个可视和隐藏节点的联合概率分布:

$$P_{\theta}(v, h) = \frac{1}{Z(\theta)} e^{-E_{\theta}(v, h)} \quad (2)$$

其中, $Z(\theta)$ 为归一化因子,也称配分函数, $Z(\theta) = \sum_{v, h} e^{-E_{\theta}(v, h)}$

求解 RBM 网络结构,即转化成用联合概率分布的边界分布(似然函数)求解参数 θ ,其表示为

$$P_{\theta}(v) = \sum_h P_{\theta}(v, h) = \frac{1}{Z(\theta)} \sum_h e^{-E_{\theta}(v, h)} \quad (3)$$

$$P_{\theta}(h) = \sum_v P_{\theta}(v, h) = \frac{1}{Z(\theta)} \sum_v e^{-E_{\theta}(v, h)} \quad (4)$$

当给定显层中各神经元的初始状态时,隐层某

个神经元处于被激活 ($h_j = 1$ 表示) 状态的概率,可由隐元激活概率式计算,即

$$P(h_j = 1 | v) = \text{sigmoid}(b_j + \sum_{i=1}^{n_v} w_{ji} v_i) \quad (5)$$

给定训练样本后训练 RBM 需要反复调整 θ 值,使得在此参数下 RBM 获得的输出概率分布尽可能与输入的训练样本数据相吻合。训练 RBM 的目标函数为

$$\max_{\theta} L_{\theta, S} = \prod_{i=1}^{n_S} P(v^i) \quad (6)$$

其中, S 为训练样本, n_S 为训练样本个数。至此,单个 RBM 的训练已完成。

1.2 深度信念网络的结构及训练过程

完整的 DBN 结构由多个 RBM 组成,其训练分成 2 个阶段:正向的预训练和反向的微调。训练 DBN 结构要对结构参数 θ 进行调整,而要想优化模型的训练性能,则要调整训练参数。考虑模型训练的时效,以及为了定量说明用智能搜索算法对训练参数进行自动寻优具有先进性,所以本文建立的 DBN 模型由 2 个 RBM 结构组成,如图 2 所示。

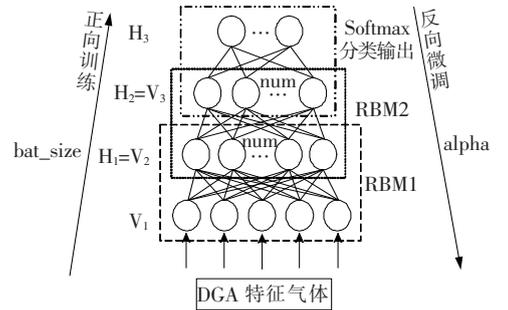


图 2 DBN 结构

Figure 2 DBN structure diagram

预训练过程:用无监督逐层训练的方法对结构参数进行初始化。将 DGA 特征气体输入到 RBM1 的显层 V_1 ,根据经验初始化训练参数批尺寸以及每层的神经元数,充分训练当前层后从隐层 H_1 输出结果,并作为下一层的输入继续训练 RBM2。

反向调优过程:运用标签数据对已经初始化好的 DBN 网络结构进行有监督调整。利用 BP 神经网络计算梯度学习率,进而用梯度下降算法更新网络的结构参数,使网络更具有全局适应性。

在通过以上 2 步训练基础 DBN 模型时,要根据

经验人工手动选择批尺寸 bat_size 、层神经元数 num 以及梯度下降学习率 α 等重要训练参数,直到计算结果满足计算精度或迭代周期要求为止。在模型训练过程中,这些参数的选取对模型的训练精度有重要影响:

1) 层神经元数 num 直接关乎 DBN 的网络结构,影响模型训练效率和精度;

2) 梯度下降学习率 α 作为反向调优中的关键参数,影响着计算结果是否能达到全局最优;

3) 批尺寸 bat_size 用于确定单次训练时样本数目,存在于 DBN 训练的全过程,影响边界数据分类的精度和训练效率。

当利用现场采集的多维原始 DGA 样本数据训练 DBN 时,依靠人工经验同时调整多个参数选值难以匹配出最合适的参数组。现有的研究通常依靠大量样本数据,并用气体含量比值的方式二次处理样本数据,以提高 DBN 模型的训练精度。

本文采用布谷鸟搜索算法对 DBN 模型中 num 、 bat_size 、 α 这 3 个重要参数同时进行自动寻优,智能匹配 3 个参数最优组合,解决人工经验选参的局限性问题,同时,采用原始数据作为训练输入,减少二次处理样本数据的工作量,以提高模型收敛性能、故障识别精度和模型泛化性能。

2 布谷鸟搜索算法

2.1 布谷鸟搜索算法的概述

CS 算法^[20]是由英国学者 Xinshe Yang 和 Suash Deb 在群体智能技术的基础上提出的一种基于自然元启发式的新型算法,该算法模拟某些种属布谷鸟的寄生育雏行为,以达到有效求解最优化问题的目的。该算法的思想基于布谷鸟的巢寄生行为和鸟类的 Levy 飞行行为,巢中的卵代表解,布谷鸟的卵代表新解,目标是利用新解或者潜在的优解将巢中的劣解更替。利用 3 条理想化规则^[21]对 CS 算法进行简单阐述:

1) 每只布谷鸟每次随机选择一个巢,并产生一个卵,即一个巢对应一个新解;

2) 具有最高质量卵的巢保留至下一代,即保留

最优的解决方案;

3) 假设寄主鸟巢的数量 N 是固定的,且寄主以 $P_a \in [0,1]$ 的概率发现布谷鸟放的卵并将布谷鸟的卵扔掉或丢弃现有的巢。

CS 算法的寻优过程由参数 P_a 控制局部随机游走和全局大跨度游走。局部随机游走可以写成

$$x_i^{t+1} = x_i^t + \alpha s \otimes H(P_a - \epsilon) \otimes (x_j^t - x_k^t) \quad (7)$$

式中 x_i^t 为任意 t 时刻第 i 个点的位置; α 为步长; $H(u)$ 为阶跃函数; \otimes 为点乘; x_j^t 、 x_k^t 为 t 时刻任意 2 个点位置。

另一方面,全局随机游走使用 Levy 飞行表示,用以更新寻找鸟巢的路线和位置^[22]:

$$x_i^{t+1} = x_i^t + \alpha L(s, \lambda) \quad (8)$$

其中, $L(s, \lambda)$ 表示随机搜索路径。鸟巢位置更新一次后,从均匀分布 $[0,1]$ 中选取随机数 r ,若 $r > P_a$,则继续更新鸟巢位置,否则维持不变,最后保留效果最好的一组鸟巢位置,仍然记作 x_i^{t+1} 。

2.2 布谷鸟搜索算法寻优 DBN 参数的步骤

布谷鸟搜索算法寻优 DBN 参数的步骤如下:

1) 用众数填充的方式处理原始样本集中的缺失数据,然后对所有数据进行 Min-Max 标准化处理,得到 DBN 训练样本集;

2) 设置迭代次数、DBN 训练参数批尺寸 bat_size 和层神经元数 num 的取值范围,考虑梯度下降学习率 α ,记训练参数组 $\eta = \{\text{bat_size}, [\text{num1}, \text{num2}], \alpha\}$;

3) 设置 CS 算法中寄主鸟发现外来卵的概率参数 P_a 为 0.25,鸟巢总数 $n=10$,随机初始巢位置为 $x_i = [x_1, x_2, \dots, x_{10}]^T, i \in [1,10]$,定义各鸟巢位置与对应训练集的适应度为 $F(x_i) = [f_1, f_2, \dots, f_{10}]^T, i \in [1,10]$;

4) 计算并比较 10 个鸟巢位置对应的适应度值,得到当前的最优适应度值 $f_{x_{\text{best}}}$,其对应当前最优的训练参数组 η_{best} ;

5) 保留上一代最优鸟巢的位置 x_{best} ,并利用 Levy 飞行随机更新其他鸟巢的位置,得到一组新的鸟巢,重新计算他们的适应度值 F ;

6)根据步骤 5 的适应度 F ,比较当前鸟巢 x_i 与上一代鸟巢位置 x_{i-1} ,用较优的鸟巢取代较劣的鸟巢,得到一组新的鸟巢位置;

7)用随机数 r 和 P_a 进行比较,若 $r > P_a$,则随机更新一次鸟巢位置,否则鸟巢位置不变;

8)若满足迭代次数要求,则继续下一步,否则重新返回步骤 5;

9)输出最优鸟巢位置,即本次 DBN 训练的最优参数组 η_{best} 。

3 变压器故障智能识别模型

3.1 故障评价及样本数据分布

在变压器故障识别的特征气体选择方面,GBT 7252—2001、IEC 60599 及现有相关研究^[23-25]常采用 5 种气体(H_2 、 CH_4 、 C_2H_2 、 C_2H_4 、 C_2H_6)作为主要的特征气体, CO 、 CO_2 仅作为辅助判断,对变压器进行故障识别。本文在保证故障识别模型计算精度的同时,兼顾算法的高效性,采用绝缘油裂解产生的 5 种故障气体(H_2 、 CH_4 、 C_2H_2 、 C_2H_4 、 C_2H_6)作为模型的训练输入。

本文将变压器状态分成健康、局部放电故障、低能放电故障、高能放电故障、中低温过热故障以及高温过热故障 6 类,其状态编码如表 1 所示。

表 1 状态类型及对应编码

Table 1 States and corresponding code

变压器状态	状态编码
健康	(0,0,0,0,0,1)
局部放电 PD	(0,0,0,0,1,0)
低能放电 D1	(0,0,0,1,0,0)
高能放电 D2	(0,0,1,0,0,0)
中低温过热 T1	(0,1,0,0,0,0)
高温过热 T2	(1,0,0,0,0,0)

本文使用的 DGA 样本数据主要来源:①从各省市供电公司收集的 DGA 数据;②IEC TC 10 数据库^[26];③近年已发表论文中确定故障类型的 DGA 数据,总计 604 组。训练集与测试集按照 4:1 划分,具体样本数据分布如表 2 所示。

表 2 训练集与测试集样本数量分布

Table 2 The distribution of the samples in the training set and the test set

变压器状态	训练样本	测试样本	合计
健康	56	14	70
PD	48	12	60
D1	58	14	72
D2	112	28	140
T1	80	20	100
T2	130	32	162
合计	484	120	604

3.2 故障识别模型的建立

本文选用 DBN 作为训练和测试模型,为了消除奇异数据、不同特征向量间的量纲影响,首先对输入的 5 种绝缘油故障气体进行 Min-Max 标准化处理。具体处理方式如下:

$$y' = \frac{y - x_{\min}}{x_{\max} - x_{\min}} \quad (9)$$

式中 y 为原始数据; y' 为归一化后的新数据; x_{\max} 为原始训练集中最大数据; x_{\min} 为原始训练集中最小数据。

经标准化处理后通过顶层 Softmax 分类器计算数据组 6 种状态的概率值,将最大概率值对应的状态视为本数组的状态类型,作为最终状态输出。另外,根据经验设置 bat_size 范围为 10~150,num 范围为 10~200,寻优迭代次数为 100 次。为了定量地分析 CS 算法对模型寻参的性能,选用遗传算法(GA)、粒子群算法(PSO)与 CS 算法作对比,分别对 DBN 模型的参数组 η 进行寻优,最后,依次比较和分析组合模型的收敛性能、故障识别精度及组合模型的泛化性能。

4 基于优化 DBN 模型的故障识别

4.1 组合优化模型收敛性能的对比分析

适应度能反应一个训练模型的收敛能力和收敛速度,本文将经 Min-Max 标准化处理后的数据集依次输入至经上述 3 种不同算法优化处理后的 DBN 模型,计算其适应度,比较、分析组合优化模型的收敛性能。3 种算法分别对 DBN 模型中参数组的寻优过程如图 3~5 所示,参数组 η_{best} 表明此时模型具有最优的收敛性能。

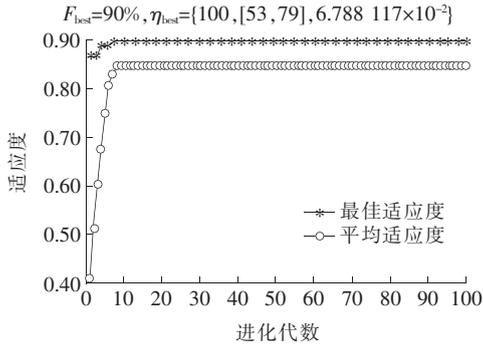


图3 GA-DBN参数组寻优

Figure 3 Optimization graph of GA-DBN parameter group

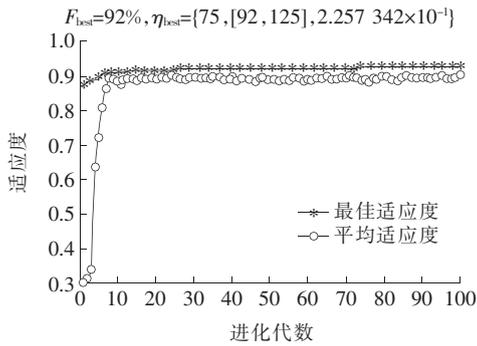


图4 PSO-DBN参数组寻优

Figure 4 Optimization graph of PSO-DBN parameter group

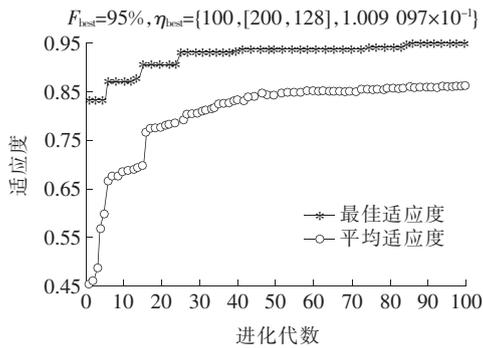


图5 CS-DBN参数组寻优

Figure 5 Optimization graph of CS-DBN parameter group

由图3~5可知,在GA-DBN、PSO-DBN的参数组寻优过程中,两者的平均适应度均从低值迅速提升到较高值后维持稳定;而从最佳适应度曲线可见,两者最佳适应度的初始值已经接近最优,其后续的进化过程较为平缓,从初始值寻优至最佳值的变化幅度不大。另外,从CS-DBN的平均适应度曲线可见,其训练的起始值就较高,且在参数组寻优过程中有较大幅度的进化;从最佳适应度曲线中可见,参

数组的寻优过程经过3次较大幅度的跃升,对比之下表明CS算法优化DBN模型,可以使得组合模型的收敛能力更强。

选取GA、PSO、CS这3种优化的最佳适应度结果,分析比较适应度与进化代数间的变化关系,如图6所示,可以看出,当适应度同为90%的情况下,GA-DBN需要7代进化,CS-DBN需要8代,进化速度相当;当适应度同为92%的情况下,PSO-DBN需要72代进化,而CS-DBN仅需32代,进化速率提升了56.2%。原因在于PSO搜索依靠个体粒子在整个全局范围进行极值计算,并以全部粒子当前最优的极值作为临时的最优中心继续返回,重复上述计算,直至最优出现;而CS搜索能在全局范围大跨度的调整寻优方向,避免在一处小局部陷入长时间的计算。因此,用CS算法优化DBN模型可以使得模型的收敛效率更高。

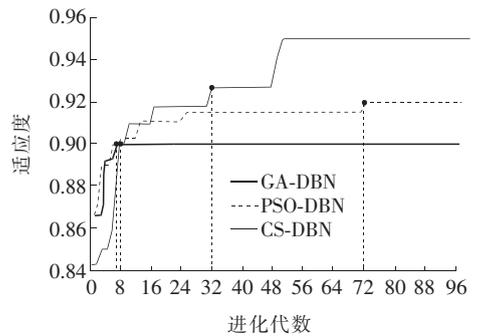


图6 故障识别率与进化代数的关系

Figure 6 The relationship between fault recognition rate and evolutionary algebra

综上所述,相比于GA-DBN、PSO-DBN,CS-DBN对参数组 η 的寻优性能更佳。

4.2 CS-DBN模型的故障识别性能分析

在最佳适应度的情况下,选取CS-DBN即参数组 $\eta_{\text{best}} = \{100, [200, 128], 1.009 097 \times 10^{-1}\}$ 时,进行6类变压器状态的识别计算,结果如图7所示,可以看出,14个健康测试样本中正确诊断分类的有14个,识别率达100%,同理,可计算得到PD、D1、D2、T1、T2状态的识别率,分别为91.7%、92.9%、92.9%、90.0%、96.9%,CS-DBN模型对变压器状态的总识别率为94.2%。

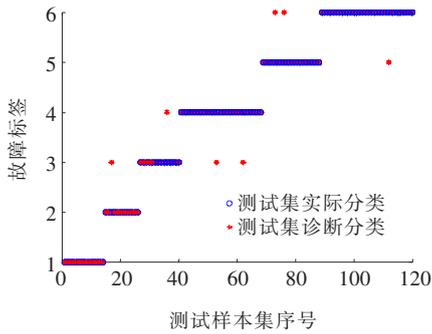


图 7 基于 CS-DBN 的变压器状态诊断结果

Figure 7 Diagnosis results based on CS-DBN

基础 DBN 模型的训练参数需要依靠人工经验选择,在经过多次反复尝试后,当选择参数组 $\eta = \{10, [100, 100], 0.015\}$ 时, DBN 模型的适应度能达到较佳的 79.3%。在 DBN、GA-DBN、PSO-DBN 各自最佳适应度的情况下,计算变压器的 6 类独立状态的故障识别率及总故障识别率。测试集故障识别率结果如表 3 所示。

表 3 测试集中变压器故障识别率结果

Table 3 Results of transformer fault recognition rate in test set %

模型	故障识别率						
	健康	PD	D1	D2	T1	T2	总
DBN	85.7	75.0	78.6	85.7	80.0	81.2	81.7
GA-DBN	92.9	83.3	92.9	92.9	85.0	90.6	90.0
PSO-DBN	100.0	83.3	85.7	96.4	85.0	93.8	91.7
CS-DBN	100.0	91.7	92.9	92.9	90.0	96.9	94.2

经过搜索算法优化后 DBN 模型的故障识别率大有提升。表 3 中结果显示,CS-DBN 比 DBN、GA-DBN、PSO-DBN 在故障总识别精度上分别高出 12.5%、4.2%、2.5%。在多参数选取与调整时,依靠人工经验显然难以实现各参数的最优匹配,而本文凭借智能搜索算法自动获取参数直接优化 DBN 模型,很好地解决了 3 个重要参数的最优组合问题。由上述故障识别率结果可以看出,通过智能搜索算法优化 DBN 训练中的关键参数和内部结构,能有效提升故障识别率。PSO-DBN 模型虽然已经能达到较高的故障识别精度,但由于 PSO 算法在迭代后期搜索能力不强,在解决多参数同时寻优搜索且计算量较大的问题时,寻优效果不及 CS 算法,从而使

得故障识别精度比 CS-DBN 模型低。

4.3 加入无关特征量后 CS-DBN 泛化性能分析

在实际工程中,采集、记录 DGA 样本数据时难免会出现错误,这将造成部分样本数据集变成无关特征干扰项。要想实现变压器故障的准确识别,就要保证 DBN 模型在含有无关特征量的情况下也能有较高的故障识别精度,即保证组合 DBN 模型具有良好的泛化性能。

为了定量分析加入不同数量无关特征数据后 CS-DBN 的泛化性能,选取基础 DBN 和故障识别精度较高的 PSO-DBN 作为对比,重新进行试验。加入的无关特征数据由服从标准正太分布的随机变量生成,均值为 0,方差为 1。加入不同数量无关特征数据后的故障识别结果如表 4 所示。

表 4 含无关特征数据时的故障识别结果

Table 4 Fault recognition results with

模型	加入无关特征数据(组)后故障识别率 %					
	0	16	32	48	64	80
DBN	94.2	90.1	86.4	82.4	78.6	73.7
PSO-DBN	91.7	90.8	88.4	86.9	83.4	80.5
CS-DBN	94.2	93.9	93.5	92.8	92.1	91.4

试验中基础 DBN 模型的参数组 η 固定选取文 4.2 中 CS-DBN 适应度为 95% 的值。由表 4 可以看到,在加入 80 组无关特征数据后,未采取优化措施的基础 DBN 模型故障识别率由 94.2% 下降至 73.7%,降低了 20.5%;而优化改进后的 CS-DBN 故障识别率仅下降至 91.4%,只降低了 2.8%,PSO-DBN 由 91.7% 下降至 80.5%,降低了 11.2%。由结果可见,采用智能搜索算法优化,依靠自动调整多参数的搭配,能明显提升 DBN 模型泛化能力,提升模型对无关特征量的适应度和故障识别精度。原因在于 PSO 搜索过程是多局部单独搜索,依据局部中最佳个体逐渐收缩,最后选择最优的局部点作为全局的最优结果,这意味着搜索过程易陷入局部最优,遗漏真正的最优结果,而 CS 算法结合局部随机游走和大跨度全局搜索,其搜索范围更广,全局搜索能力更强,能适应加入无关特征数据后规律性更差的样本数据,因此用 CS-DBN 模型泛化性能更强。

5 结语

用变压器油中溶解气体原始数据作为 DBN 模型的输入数据,通过 CS 算法优化改进能提高变压器故障识别精度和进化效率,提升组合模型的泛化能力,适应不同的样本数据。

1)在较少原始 DGA 训练样本的情况下,智能搜索算法优化后的 DBN 模型比基础 DBN 模型的故障识别能力大大增强。CS-DBN 的最佳故障总识别率能达到 94.2%,精度上比 CA-DBN 提高 4.2%,比 PSO-DBN 提高 2.5%。

2)CS 算法能在全局大跨度调整搜索方向,因此搜索效率有明显优势。CS-DBN 的进化效率较 PSO-DBN 提高 56.2%。

3)加入无关特征量后 CS-DBN 仍能保持良好的故障识别效果。加入 80 组无关特征量后故障识别率仅下降 2.8%,CS-DBN 组合模型较 GA-DBN 和 PSO-DBN 的泛化性能优越。

参考文献:

[1] GBT 7252—2001. 变压器油中溶解气体分析和判断导则[S].

[2] IEC 60599—2015. Mineral oil-filled electrical equipment in service-guidance on the interpretation of dissolved and free gases analysis[S].

[3] 刘慧鑫,连鸿松,张江龙,等. 变压器油中溶解气体在线监测装置运行质量指标及评价体系[J]. 高压电器, 2021,57(1):143-149.
LIU Huixin, LIAN Hongsong, ZHANG Jianglong, et al. Operation quality index and evaluation system of on-line monitoring device for gases dissolved in transformer oil[J]. High Voltage Apparatus, 2021, 57(1): 143-149.

[4] DUVAL M, LAMARRE L. The duval pentagon-a new complementary tool for the interpretation of dissolved gas analysis in transformers[J]. IEEE Electrical Insulation Magazine, 2014, 30(6): 9-12.

[5] 张宗喜,刘睿,聂鸿宇,等. 微氧作用下天然酯变压器油热老化特性研究[J]. 电测与仪表, 2021, 58(12): 63-68.
ZHANG Zongxi, LIU Rui, NIE Hongyu, et al. Study on

thermal aging characteristics of natural ester transformer oil under micro-oxygen[J]. Electrical Measurement & Instrumentation, 2021, 58(12): 63-68.

[6] IEEE C57. 104—2019. IEEE guide for the interpretation of gases generated in mineral oil-immersed transformers[S].

[7] DUVAL M. A review of fault detectable by gas-in-oil analysis in transformers[J]. IEEE Electrical Insulation Magazine, 2002, 18(3): 8-7.

[8] GHUNEM R A, ASSALEH K, EL-HAG A H. Artificial neural networks with stepwise regression for predicting transformer oil furan content[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2012, 19(2): 414-420.

[9] 袁佳波,徐鹏程,李磊,等. 基于鸡群优化 BP 神经网络的变压器油纸绝缘老化预测方法[J]. 电力科学与技术学报, 2020, 35(4): 33-41.
YUAN Jiabo, XU Pengcheng, LI Lei, et al. Prediction of transformer oil-paper insulation aging based on BP neural networks with the chicken swarm optimization algorithm[J]. Journal of Electric Power Science and Technology, 2020, 35(4): 33-41.

[10] 党东升,张树永,葛鹏江,等. 基于改进粒子群优化支持向量机的变压器故障诊断方法[J]. 电力科学与技术学报, 2019, 34(3): 108-113.
DANG Dongsheng, ZHANG Shuyong, GE Pengjiang, et al. Transformer fault diagnosis method based on support vector machine optimized by improved quantum-behaved particle swarm optimization[J]. Journal of Electric Power Science and Technology, 2019, 34(3): 108-113.

[11] 李广原,杨炳儒,刘英华,等. 基于模糊论的数据挖掘研究综述[J]. 计算机工程与设计, 2011, 32(12): 4064-4067.
LI Guangyuan, YANG Bingru, LIU Yinghua, et al. Survey of data mining based on fuzzy set theory[J]. Computer Engineering and Design, 2011, 32(12): 4064-4067.

[12] 吴宝春. 基于遗传算法和灰色理论的电力变压器故障预测的研究[D]. 长春: 吉林大学, 2009.

[13] HINTON G, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313: 504-507.

- [14] 任双赞,徐尧宇,李元,等. 应用于油中溶解气体分析的深度信念网络与典型神经网络对比研究[J]. 高压电器,2020,56(9):39-45.
REN Shuangzan, XU Yaoyu, LI Yuan, et al. Comparison studies of deep belief network and typical neural network applied to analysis of dissolved gas in oil[J]. High Voltage Apparatus, 2020, 56(9): 39-45.
- [15] 荣智海,齐波,李成榕,等. 面向变压器油中溶解气体分析的组合 DBN 诊断方法[J]. 电网技术,2019,43(10):3801-3807.
RONG Zhihai, QI Bo, LI Chengrong, et al. Combined DBN diagnosis method for dissolved gas analysis of power transformer oil[J]. Power System Technology, 2019, 43(10): 3801-3807.
- [16] 苏磊,陈璐,徐鹏,等. 基于深度信念网络的变压器运行状态分析[J]. 高压电器,2021,57(2):56-62.
SU Lei, CHEN Lu, XU Peng, et al. Operation condition analysis of transformer based on deep belief network[J]. High Voltage Apparatus, 2021, 57(2): 56-62.
- [17] 孔灿,张大宁,田杰,等. 110 kV 变压器油纸绝缘套管不均匀绝缘受潮劣化分析[J]. 智慧电力,2020,48(4):119-124.
KONG Can, ZHANG Daning, TIAN Jie, et al. Non-uniform moisture degradation analysis of 110 kV transformer oil-paper insulation bushing[J]. Smart Power, 2020, 48(4): 119-124.
- [18] 刘方园,王水花,张焜东,深度置信网络模型即应用研究综述[J]. 计算机工程与应用,2018,54(1):11-18.
LIU Fangyuan, WANG Shuihua, ZHANG Yudong, et al. Survey on deep belief network model and its applications[J]. Computer Engineering and Applications, 2018, 54(1): 11-18.
- [19] 张健,丁世飞,张楠,等. 受限玻尔兹曼机研究综述[J]. 软件学报,2019,30(7):2073-2090.
ZHANG Jian, DING Shifei, ZHANG Nan, et al. A review of restricted boltzmann machines[J]. Journal of Software, 2019, 30(7): 2073-2090.
- [20] YANG X S, DEB S. Cuckoo search via levy flights[C] // IEEE 2009 World Congress on Nature & Biologically Inspired Computing (NaBIC), Coimbatore, India, 2009.
- [21] 张晓凤,王秀英. 布谷鸟搜索算法综述[J]. 计算机工程与应用,2018,54(18):8-15.
ZHANG Xiaofeng, WANG Xiuying. Survey of cuckoo search algorithm[J]. Computer Engineering and Applications, 2018, 54(18): 8-15.
- [22] 李亮,范瑾,闫林,等. 基于混合采样和支持向量机的变压器故障诊断[J]. 中国电力,2021,54(12):150-155.
LI Liang, FAN Jin, YAN Lin, et al. Transformer fault diagnosis based on hybrid sampling and support vector machines[J]. Electric Power, 2021, 54(12): 150-155.
- [23] 朱保军,咸日常,范慧芳,等. WRSR 与改进朴素贝叶斯融合的变压器故障诊断技术研究[J]. 电力系统保护与控制,2021,49(20):120-128.
ZHU Baojun, XIAN Richang, FAN Huifang, et al. Transformer fault diagnosis technology based on the fusion of WRSR and improved naive Bayes[J]. Power System Protection and Control, 2021, 49(20): 120-128.
- [24] 沙伟燕,李秀广,何宁辉,等. 基于油色谱时频域信息和残差注意网络的变压器故障诊断方法[J]. 电网与清洁能源,2022,38(1):66-75.
SHA Weiyan, LI Xiuguang, HE Ninghui, et al. Transformer fault diagnosis method based on oil chromatogram time-frequency domain information and residual attention network[J]. Power System and Clean Energy, 2022, 38(1): 66-75.
- [25] 郭慧莹,王毅. 基于 DGA 支持向量机的变压器故障诊断[J]. 现代电子技术,2019,42(19):154-158+163.
GUO Huiying, WANG Yi. Transformer fault diagnosis based on DGA support vector machine[J]. Modern Electronics Technique, 2019, 42(19): 154-158+163.
- [26] DUVAL M, dePABLE A. Interpretation of gas-in-oil analysis using new IEC publication 60599 and IEC TC 10 databases[J]. IEEE Electrical Insulation Magazine, 2001, 17(2): 31-41.