基于自适应极限学习机的变压器故障识别方法

吴杰康,覃炜梅,梁浩浩,金尚婷,罗伟明 (广东工业大学 自动化学院,广东 广州 510006)

摘要:针对变压器状态数据累积规模和复杂程度均增大的情况,单一智能算法进行数据处理的能力有限、精 度低,提出了基于自适应极限学习机的变压器故障识别方法。利用免疫算法(IA)的多样性调节机制和存储 机制对粒子种群进行优、劣分类,对优、劣粒子分别采用不同的进化方式。经IA改进的粒子群优化(PSO)算 法有效克服了种群容易早熟从而导致进化停滞的缺点,提高了全局寻优能力。在参数寻优的基础上,根据寻 优输出结果建立变压器故障识别模型。实验计算结果表明所提方法比极限学习机(ELM)、粒子群优化极限 学习机(PSO-ELM)、遗传算法优化极限学习机(GA-ELM)方法的故障识别精度高。

关键词:电力变压器;故障识别;免疫算法;粒子群优化算法;极限学习机 中图分类号:TM 41

文献标志码:A

DOI:10.16081/j.epae.201908037

0 引言

电力变压器作为电力系统中的重要一次设备, 提高其故障诊断准确率对设备的运行维护工作具有 十分重要的意义。随着大数据以及智能算法的广泛 应用,研究者们提出了许多结合算法的变压器故障 诊断方法。文献[1]通过计算比较已知和未知样本 的权值,判断未知样本是否属于已知类别,在此基础 上进一步对属于已知类别的待分类样本进行分类计 算,该方法综合了Otsu准则、模糊C均值(FCM)和支 持向量机(SVM)算法,有效实现了放电信号识别;文 献[2]利用概率神经网络(PNN)构建变压器故障诊 断模型,并通过主成分分析(PCA)提取关键指标作 为模型输入,提高了模型的诊断精度;文献[3]利用 集对分析和关联规则量化指标与故障状态的关系, 深入挖掘数据间的信息;文献[4]以电气和非电气量 作为研究对象,利用深度置信网络对数据进行特征 提取,结合D-S证据理论构造多级故障决策模型;文 献[5]以在线检测数据为研究对象,构建分类深度自 编码网络模型,有效利用了无标签样本。然而上述 方法中,面对大规模数据时,SVM耗时长、精度低; FCM 对参数和训练样本敏感;关联规则对源数据的 要求高;D-S证据理论无法准确应对证据严重冲突 甚至完全冲突的情况;PCA对维度不高的数据信息

收稿日期:2019-01-30;修回日期:2019-04-30

基金项目:国家自然科学基金资助项目(51567002,507670-01);广东省公益研究与能力建设专项资金资助项目 (2014A010106026);广东省应用型科技研发专项资金资助 项目(2016B020244003)

Project supported by the National Natural Science Foundation of China (51567002, 50767001), Guangdong Special Fund for Public Welfare Study and Ability Construction (2014A0101-06026) and Guangdong Applied Science and Technology Research Foundation(2016B020244003)

损失较大。

由于故障诊断方法面向的变压器状态数据的规 模越来越大,复杂程度越来越高,单一算法的计算推 理能力已不能满足要求。本文提出了基于综合多种 算法优点的自适应极限学习机 SA-ELM (Self-Adaptive Extreme Learning Machine)的变压器故障识别 方法。该方法利用极限学习机(ELM)构建变压器故 障识别模型。由于 ELM 受初始随机生成参数的影 响,损失函数较大、鲁棒性差、计算精度低,对此本文 利用结合免疫算法的粒子群优化(IA-PSO)算法对 ELM参数进行优化。通过免疫算法(IA)对种群的多 样性与适应度进行自适应地均衡调整,既强化了算 法的全局寻优能力,又兼顾了局部细致搜索。

根据导则[6]以及三比值法原理[7]可知,在电、 磁、热的重叠作用下,变压器内部绝缘油发生劣化分 解。当发生不同程度、不同类型的故障时,绝缘油分 解为不同含量、不同组成成分的气体。因此本文选 取油中溶解气体(H₂、CH₄、C₂H₂、C₂H₄、C₂H₆)作为变 压器故障诊断的特征指标。最后进行算例计算分 析,并将本文所提方法与ELM、粒子群优化极限学习 机(PSO-ELM)、遗传算法优化极限学习机(GA-ELM)方法在计算速度和精度方面进行比较,结果表 明本文所提方法寻优能力强、速度快、计算稳定性和 精度高,可有效识别变压器的状态。

1 IA-PSO算法

粒子群优化(PSO)算法的核心公式为速度和空 间位置的更新公式[8],分别如式(1)和式(2)所示。 结合竞争机制,使得每次进化保留下来的始终是粒 子个体最优位置以及全局最优位置,该进化过程即 最优解的搜索过程。

$$\boldsymbol{v}_{i}^{t+1} = \boldsymbol{\sigma}^{t+1} \boldsymbol{v}_{i}^{t} + c_{1} r_{1} \left(\boldsymbol{p}_{\text{best}i}^{t} - \boldsymbol{p}_{i}^{t} \right) + c_{2} r_{2} \left(\boldsymbol{p}_{\text{gbest}}^{t} - \boldsymbol{p}_{i}^{t} \right) \quad (1)$$
$$\boldsymbol{p}_{i}^{t+1} = \boldsymbol{p}_{i}^{t} + \boldsymbol{v}_{i}^{t+1} \qquad (2)$$

其中,t为迭代次数; c_1 、 c_2 为粒子学习因子; r_1 和 r_2 为 [0,1]区间内的随机数; v_i 、 p_i^t 分别为第i个粒子在第t次迭代时的速度、解空间位置; p_{gbest}^t 、 p_{best}^t 分别为第t次迭代的全局、个体最优位置; σ 为惯性因子。

PSO算法在工程规划、函数优化、组合优化等领域中已获得了较好的应用。由于PSO算法在进化过程中种群趋同性强、后期收敛速度慢,容易陷入进化停滞,最终导致精度低^[9-10],本文利用IA的多样性调节机制、记忆存储机制和疫苗接种机制^[11-12]对PSO算法进行改进,使得种群朝最优解方向进化的同时保持多样性,实现种群进化过程中自适应的全局搜索能力。

1.1 多样性调节机制

为了使种群在进化过程中追求粒子高适应度的 同时能够保持多样性,避免整体陷入局部极值,本文 利用粒子亲和力实现种群多样性的调节。亲和力由 粒子浓度和适应度构成,反映了候选解与目标的接 近程度以及粒子间的差异程度,计算公式如式(3) 所示。

$$\delta_i = \alpha f(\mathbf{p}_i) + (1 - \alpha) e^{-d(\mathbf{p}_i)}$$
(3)

其中,α为比例因子,表示适应度对亲和力的影响比 重;f(p_i)为第*i*个粒子的适应度;d(p_i)为第*i*个粒子 的浓度。本文采用海明距离计算粒子浓度,计算公 式如式(4)和式(5)所示。

$$\begin{cases} \rho(p_{i}) = \sum_{j=1}^{M} a_{j} \\ a_{j} = \begin{cases} 1 & 0.95 \leq p_{i}/p_{j} \leq 1.01 \\ 0 & \ddagger \& \end{cases} \quad i, j=1, 2, \cdots, M \coprod i \neq j \end{cases}$$
(4)

$$d(\mathbf{p}_i) = \frac{\rho(\mathbf{p}_i)}{M} \quad i=1,2,\cdots,M \tag{5}$$

其中,ρ(p_i)为第i个粒子与其余粒子之间对应属性 比值,表示第i个粒子与其他所有粒子相聚集的程 度;M为种群规模。海明距离对于高度趋同的种群 十分敏感,能够有效反映种群在空间分布的浓密 程度。

1.2 记忆存储机制

在每次进化更新过程中,结合多样性调节机制的调整作用,将种群S分类保存至2个子群,优秀粒子保存到子群S_A,剩余的劣势粒子保存到子群 S_B,即:

$$S_{A} \leftarrow \left| S(\delta_{\max}, k) \right|$$
 (6)

$$S_{\rm B} \leftarrow \left| S(\delta_{\min}, M - k) \right|$$
 (7)

其中,|·|表示粒子群;S为种群,由M个粒子构成; $S(\delta_{max},k)$ 表示取种群S中具有最大亲和力的k个粒 子, δ_{max} 为粒子的最大亲和力; $S(\delta_{min}, M-k)$ 表示取 种群S中剩余的M-k个具有最小亲和力的粒子, δ_{min} 为粒子的最小亲和力。

1.3 疫苗接种机制

对进化落后的粒子进行有目的的疫苗接种,可 改善种群质量,促进种群发展。由于全局最优粒子 所携带的特征信息和先验知识最接近目标解,因此 疫苗以全局最优粒子作为取样信息的有效对象。

$$\boldsymbol{V}_{\rm acc}^t = \boldsymbol{p}_{\rm gbest}^t + \boldsymbol{a}^t \tag{8}$$

其中,V_{acc}为进化到第t次迭代时的疫苗;a^t为随机生成的小变量,用于避免疫苗与全局最优位置高度重叠。疫苗接种的方式主要有2种:一种方式是采取优秀粒子作为疫苗,直接覆盖取代适应度低的粒子,这样虽然保证了种群质量,但容易形成大规模的粒子趋同,加速整体陷入局部极值;另一种方式为随机部分接种,该方式侧重于维持种群的多样性和繁殖能力,但大范围搜索使得收敛速度减慢。

本文通过多样性调节机制和记忆存储机制将种 群一分为二,将低浓度、高适应度的优秀粒子群存储 于子群S_A,并对其进行标准粒子群更新进化,使得优 秀基因得以延续,抑制种群严重退化;将剩余的高浓 度、低适应度的劣势粒子存储于子群S_B。对该组进 化相对落后的子群S_B进行疫苗随机部分接种更新, 促进劣势粒子的发展,使得粒子在解空间进一步分 散,扩大搜索范围。这种分类进化的方式不仅保持 了种群的多样性和进化能力,也避免了大范围粒子 接种导致收敛速度慢以及资源浪费的问题。

2 ELM

ELM 是一种单隐含层前向神经网络结构的智能 算法,具有结构灵活、计算简单、学习速度快、普适性 好、参数少的优点,因此在学术研究和工程领域中获 得了广泛的应用^[13],其数学模型如式(9)所示。

$$H\beta = O$$
(9)
$$H(w_1, \cdots, w_l, x_1, \cdots, x_N, b_1, \cdots, b_l) = \begin{bmatrix} g(w_1 x_1 + b_1) & g(w_2 x_1 + b_2) & \cdots & g(w_l x_1 + b_l) \\ g(w_1 x_2 + b_1) & g(w_2 x_2 + b_2) & \cdots & g(w_l x_l + b_l) \end{bmatrix}$$

$$\begin{bmatrix} \vdots & \vdots & \vdots \\ g(\boldsymbol{w}_1\boldsymbol{x}_N+b_1) & g(\boldsymbol{w}_2\boldsymbol{x}_N+b_2) & \cdots & g(\boldsymbol{w}_l\boldsymbol{x}_N+b_l) \end{bmatrix}$$
(10)

其中,*H*为隐含层输出矩阵; β 为输出层权值;O为模型计算输出; $w_i = [w_{i1}, w_{i2}, \dots, w_{in}](i=1,2,\dots,l)$ 为输入层与隐含层神经元之间的连接权值,l为隐含层神经元之间的连接权值,l为隐含层神经元个数,n为样本属性长度; $x_i = [x_{i1}, x_{i2}, \dots, x_{in}]^{T}(i=1,2,\dots,N)$ 为输入样本,共有N组; $b_i(i=1,2,\dots,l)$ 为隐含层神经元偏置值; $g(\cdot)$ 为具有无限可微特性的激活函数。文献[13-14]指出给定激活函数 $g(\cdot)$ 和训练样本集(x_i, y_i)($i=1, 2, \dots, N$),随机生成一组权值w和偏置值b,通过求解式(11)的最小二乘解,可

唯一确定一组 $\beta = H^+Y$ 满足条件 $||H\beta - Y|| \leq \varepsilon$,其中 ε 为给定阈值。

$$\min_{\boldsymbol{\beta}} \left\| \boldsymbol{H}\boldsymbol{\beta} - \boldsymbol{Y} \right\|_{2}^{2} \tag{11}$$

3 变压器故障识别方法

ELM模型的训练实质是通过求解目标函数的最 小范数二乘解来寻找模型的最优参数组合(*w*,*b*, β),服从经验风险最小化以及结构风险最小化原则, 因此算法存在过拟合、鲁棒性不足、精度不高的问 题。通过对算法本身进行改进或借助相关优化算法 进行参数优化,可提高计算精度^[15-17]。本文利用IA-PSO算法对模型参数进行寻优,其中以ELM训练输 出分类精度作为粒子的适应度,根据寻优结果建立 变压器故障识别模型,算法的具体实现流程如图1 所示。





算法的关键计算步骤如下:

(1)初始化模型参数和种群,并计算初始种群*s*的粒子适应度;

(2)令迭代计数t=1,开始迭代计算;

(3)根据式(4)和式(5)计算粒子浓度,并根据式(3)计算粒子亲和力;

(4)依据多样性调节机制和记忆存储机制原理, 将种群一分为二,分别为存储至子群*S*_A和*S*_B;

(5)根据式(1)和式(2)对子群 S_A 进行位置更新 并计算粒子适应度,根据粒子适应度竞争机制更新 S_A 的个体最优 $p'_{\text{best A}}$;

(6)根据式(8)所示疫苗选择方式提取疫苗信息,对劣势子群S_B进行疫苗接种;

(7)计算疫苗接种后子群 $S_{\rm B}$ 的粒子适应度,并根据粒子适应度竞争机制更新 $S_{\rm B}$ 的个体最优 $p_{\rm best B}^{i}$;

(8)将 S_A 和 S_B 重新合并成种群S,并根据式(1)、 (2)对种群S进行位置更新以及计算粒子适应度,根据适应度竞争机制对S的个体最优 p'_{best} 和全局最优 p'_{gbest} 进行更新;

(9)判断是否满足迭代条件,当满足目标阈值或 迭代次数大于最大迭代次数时,退出循环并输出结 果,否则迭代计数t加1,并返回步骤(3);

(10)取步骤(9)的输出结果作为建模参数,建立 基于 ELM 的变压器故障诊断模型;

(11)将测试样本集输入步骤(10)建立的模型并 统计算计输出结果精度。

4 算例计算与分析

4.1 样本选取与算例参数预设

算例样本采用广东省河源供电局提供的已知故 障状态的503组历史数据,指标有油中溶解气体H₂、 CH₄、C₂H₂、C₂H₄、C₂H₆,表征了正常(N)、低温故障 (T₁)、中温故障(T₂)、高温故障(T₃)、低能放电(D₁)、 高能放电(D₃)6种状态。算例随机选取60%的样本 作为训练样本,剩余样本为测试样本,如表1所示。 数据表征状态采用编码形式作为计算输出,如表2 所示。

算例参数预设如下:种群S的总规模 $M=40, \rightarrow$ 群 S_A 和 S_B 的分类比例为3:1;惯性因子 σ 采用随进化次数线性递减的取值方式,上、下限分别取为1.0和0.1;最大迭代次数取500次;速度v的上、下限分别为1和-1;学习因子 c_1 和 c_2 均取值为2;疫苗接种范

Table 1 Training and testing sample sets

拦木住			样本数	量/组			스러
什个朱	Ν	T_1	T_2	T_3	D_1	D_3	百月
训练集	58	42	52	60	28	59	299
测试集	40	29	35	40	20	40	204

表 2 故障状态与对应编码 Table 2 Fault states and corresponding codes

状态	编码	状态	编码
Ν	(1, -1, -1, -1, -1, -1)	T ₃	(-1,-1,-1,1,-1,-1)
T_1	(-1, 1, -1, -1, -1, -1)	D_1	(-1,-1,-1,-1,1,-1)
T_2	(-1, -1, 1, -1, -1, -1)	D ₃	(-1,-1,-1,-1,-1,1)

围取种群规模的50%;疫苗接种长度取50位;迭代 目标阈值为0.98,即故障识别正确率要求为98%及 以上;随机生成种群初始速度v_{Mxs}和位置p_{Mxs},其中 s=l×(n+1)为粒子长度,l为ELM模型隐含层神经元 个数,根据试错法令l=20,n为输入神经元个数,由输 入样本属性长度知n=5,根据输出状态编码知输出 神经元个数为6;模型激活函数采取Sigmoid函数。

4.2 模型训练与测试

算例在 Intel(R) Core(TM) i5-4590, 3.30 GHz, 内存8 GB的环境下,利用 MATLAB2015b 进行编程, 输入预设参数和训练样本进行变压器故障识别模型 训练,图2为适应度进化曲线。由图可知,算法在第 221次迭代计算时,适应度(训练集识别正确率)达 到98.33%,大于预设目标阈值98%,退出迭代计算 并输出参数寻优结果。



Fig.2 Change curve of fitness vs. number of iteration

利用参数寻优输出结果构建变压器故障识别模型,输入测试样本计算得到整体测试识别正确率为 93.63%,具体故障识别结果如表3所示。由表3可 知,测试样本中表征正常状态的样本全部被正确识 别;低温故障误判样本为2组;中温和高温故障误判 样本均为1组;表征低能放电故障的样本中被误判 的样本为3组,识别正确率最低,为85%;高能放电 故障样本组中被误判的样本最多,为5组,识别正确 率为87.5%。可见所建立模型对测试样本中所包含

表 3 测试集故障识别组	宇果
--------------	----

Table 3 Fault identification results of testing set

								8
实际	样本数			识别	结果			识别
状态	量/组	Ν	T_1	T_2	Τ3	D_1	D_3	正确率/%
Ν	40	40	0	0	0	0	0	100.00
T_1	29	0	27	2	0	0	0	93.10
T_2	35	0	0	34	1	0	0	97.14
T_3	40	0	0	0	38	0	1	95.00
D_1	20	0	0	1	0	17	2	85.00
D_3	40	0	0	1	3	1	35	87.50

的每一种故障状态类型均可有效识别。

为了对算法的计算稳定性进行说明,实验连续进行100次计算,并对100次训练集和测试集的识别 正确率进行统计计算,结果如表4所示。训练样本 和测试样本的平均故障识别正确率分别为97.98% 和90.68%,两者的均方差分别为1.61和3.68,波动 较小。通过本文所提方法对模型随机生成参数进行 寻优,寻优结果总能将训练和测试精度分别保持在 97.98%和90.68%左右,说明了本文所提方法能够 稳定保持高精度的计算输出。

表 4 训练和测试集识别正确率的统计结果 Table 4 Statistical results of identification accuracy of

	training	g and testing	, sets	
样本集	最大 正确率 / %	最小 正确率 / %	平均 正确率 / %	正确率 方差
训练集	98.66	95.32	97.98	1.61
测试集	95.10	86.27	90.68	3.68

4.3 方法比较

实验使用ELM、PSO-ELM、GA-ELM和本文所提 SA-ELM 对同一组样本进行计算比较。图3为在相 同预设参数情况下各方法的适应度进化曲线。由图 可看出,SA-ELM在第194次迭代计算时适应度大于 预设目标阈值,即训练精度超过98%,参数寻优完 成,退出迭代计算,SA-ELM在第1—194次迭代的收 敛速度快,期间以适应度退化为代价强制进行全局 寻优和局部细致搜索,最终以98.66%的适应度完成 最优解搜索任务: PSO-ELM 在前 100 次迭代进化中 保持快速学习,中期进化速度减缓,并于350次迭代 后开始陷入局部极值,收敛于92.75%的训练精度; GA-ELM从第100次迭代开始进化陷入停滞,并收敛 于 87.50% 的训练正确率。可见, PSO-ELM 和 GA-ELM的最终输出精度均远低于目标精度要求。SA-ELM的适应度在进化过程中存在最大幅度为4.02% 的退化,种群退化在可接受范围内。SA-ELM 自第 40次迭代开始适应度始终高于 PSO-ELM 和 GA-ELM 的适应度,说明本文所提方法的寻优能力比 较好。



图 3 3 种方法的适应度曲线比较

Fig.3 Comparison of fitness curves among three methods

ELM、PSO-ELM、GA-ELM 和本文所提 SA-ELM 利用同一组训练样本建立模型后,输入同一组测试

样本进行故障诊断识别,结果如表5所示。

	表5	不同方	了法	的识别正确	率比较	
Table 5	Com	parison	of	calculation	accuracy	among
		diff	erer	nt methods		

方法	隐含层 神经数 / 个	训练集识别 正确率 / %	测试集识别 正确率 / %	计算 时间 / s
ELM	20	78.50	77.67	0.0537
PSO-ELM	20	90.00	87.38	26.0760
GA-ELM	20	87.50	82.52	25.0940
SA-ELM	20	97.66	93.63	21.3750

由表5所示结果可知,本文所提方法的训练集 和测试集识别正确率均比ELM、PSO-ELM和GA-ELM方法高。ELM采用随机生成参数,无参数寻优 过程,虽然计算速度快,但是精度低。PSO-ELM和 GA-ELM的计算精度表明采用优化算法对模型参数 进行寻优可有效提高算法的输出精度,但会导致算 法更复杂,计算量增加,耗时更长。虽然本文所提方 法在PSO-ELM的基础上进行改进,计算更复杂,但 耗时较PSO-ELM和GA-ELM均短,这是因为改进后 算法的全局寻优能力强,通过快速找到满足预设要 求的全局最优解,减少了计算耗时。

4.4 实例计算

利用上述模型对来自广东省河源供电局的6组 变压器检测异常数据进行故障识别,样本如表6 所示。

			1		
它早		油中溶解	译气体含量 /	$(\mu L \cdot L^{-1})$	
厅 5	H_2	CH_4	C_2H_6	C_2H_4	C_2H_2
1	6.54	745.22	2734.90	2132.60	1467.90
2	0	14.33	76.03	131.53	371.42
3	24.21	39.94	84.06	8.78	64.44
4	286.54	843.24	1284.50	2135.50	2055.80
5	0	114.18	0	0	0
6	100.11	24.66	7.13	0	3.74

表6 故障样本 Table 6 Fault samples

表7为SA-ELM模型和IEC三比值法^[18]对6组样本的诊断结果以及停运检测原因。由于IEC三比值法的编码边界太过于绝对,编码不完全,无法有效识

表7	故障样本识别结果

Table 7	Identification	results	of	fault	sample
14010 /	raemineation	1004100	01	Incole	bampie

	故障识	别结果	
序号	IEC 三比值法	SA-ELM 模型	停运检测原因
1	低能放电	高能放电	C相避雷器遭雷击,变压器 C相受影响而烧坏
2	不能识别	高能放电	长期重载运行
3	高能放电	高能放电	变压器外壳遭到雷击,高压侧及 低压侧对地绝缘受损
4	低能放电	高能放电	运行时间较长,绝缘老化严重, 且由于用电量增大,超过运行额定 容量,变压器绕组B相烧断
5	不能识别	高温故障	长期重载运行
6	不能识别	低温故障	长期重载运行

别处于编码模糊区间的第2、5、6组样本。SA-ELM 故障识别模型的诊断结果显示第1—4组为高能放 电故障,第5、6组分别为高温故障和低温故障。参 考导则故障分析第1—4组故障的可能原因是过电 流导致线圈匝间、层间击穿短路;第5、6组变压器均 处于长期重载运行,长期过载电流损耗引起铜过热, 导致绝缘导线过热甚至绝缘不良。

5 结论

本文提出了结合IA和PSO算法的SA-ELM变压 器故障识别方法。所提方法利用IA辅助PSO算法 实现算法在粒子适应度与种群多样性的自适应调 整,使得种群在向最优解进化的过程中保持相对的 种群多样性。通过均衡种群多样性和适应度,维持 了种群的繁殖进化能力,从而在兼顾局部细致搜索 的同时扩大了全局寻优能力,有效克服了粒子群容 易早熟、进化停滞的缺点,提高了寻优精度。

利用寻优结果构建变压器故障识别模型,通过 连续多次重复计算统计平均故障识别正确率及其方 差,结果表明本文所提方法的计算稳定性较好、精度 高。将本文所提方法与基于ELM、PSO-ELM和GA-ELM的变压器故障诊断方法的结果进行比较,表明 本文所提方法具有快速的学习能力、更高的诊断正 确率。

参考文献:

[1] 贾亚飞,朱永利,高佳程,等. 基于样本加权 FCM 聚类的未知 类别局部放电信号识别[J]. 电力自动化设备,2018,38(12): 107-112.

JIA Yafei, ZHU Yongli, GAO Jiacheng, et al. Recognition of unknown partial discharge signals based on sample-weighted FCM clustering[J]. Electric Power Automation Equipment, 2018,38(12):107-112.

- [2]苑津莎,尚海昆.基于主成分分析和概率神经网络的变压器局部放电模式识别[J].电力自动化设备,2013,33(6):27-31.
 YUAN Jinsha, SHANG Haikun. Pattern recognition based on principal component analysis and probabilistic neural networks for partial discharge of power transformer[J]. Electric Power Automation Equipment,2013,33(6):27-31.
- [3] 谢龙君,李黎,程勇,等.融合集对分析和关联规则的变压器故障诊断方法[J].中国电机工程学报,2015,35(2):277-286.
 XIE Longjun,LI Li,CHENG Yong, et al. A fault diagnosis method of power transformers by integrated set pair analysis and association rules[J]. Proceedings of the CSEE, 2015, 35 (2):277-286.

[4] 李刚,于长海,范辉,等. 基于多级决策融合模型的电力变压器 故障深度诊断方法[J]. 电力自动化设备,2017,37(11): 138-144.
LI Gang,YU Changhai,FAN Hui,et al. Deep fault diagnosis of power transformer based on multilevel decision fusion model

 [J]. Electric Power Automation Equipment, 2017, 37(11): 138-144.
 [5] 石鑫,朱永利,宁晓光,等. 基于深度自编码网络的电力变压器

5] 石霾,禾水利,丁啶元,寺. 基丁保度目编时网络的电力变压器 故障诊断[J]. 电力自动化设备,2016,36(5):122-126. SHI Xin,ZHU Yongli,NING Xiaoguang, et al. Transformer fault diagnosis based on deep auto-encoder network [J]. Electric Power Automation Equipment, 2016, 36(5):122-126.

- [6] 国家电网公司.油浸式变压器(电抗器)状态评价导则:Q/ GDW 169-2008[S].北京:中国电力出版社,2008.
- [7] IEEE. IEEE guide for the interpretation of gases generated in oil-immersed transformers: IEEE C57.104-2008 [S]. [S.I.]: IEEE,2018.
- [8] KENNEDY J, EBERHART R. Particle swarm optimization[C]// Proceedings of ICNN' 95-International Conference on Neural Networks. New York, USA: IEEE, 1995:1942-1948.
- [9] 戎汉中.面向组合优化问题的粒子群算法的研究[D].南京: 南京邮电大学,2017.
 RONG Hanzhong. Research on particle swarm optimization algorithm for solving combinatorial optimization problems [D].
 Nanjing: Nanjing University of Posts and Telecommunications, 2017.
- [10] KHARE A, RANGNEKAR S. A review of particle swarm optimization and its applications in solar photovoltaic system [J]. Applied Soft Computing, 2013, 13(5):2997-3006.
- [11] 莫宏伟.人工免疫系统原理与应用[M].哈尔滨:哈尔滨工业 大学出版社,2002:51-104.
- [12] 熊虎岗,程浩忠,李宏仲.基于免疫算法的多目标无功优化
 [J].中国电机工程学报,2006,26(11):102-108.
 XIONG Hugang,CHENG Haozhong,LI Hongzhong. Multi-objective reactive power optimization based on immune algorithm
 [J]. Proceedings of the CSEE,2006,26(11):102-108.
- [13] HUANG G B,ZHU Q Y,SIEW C K. Extreme learning machine: a new learning scheme of feedforward neural networks [J]. Neurocomputing, 2006, 70:489-501.
- [14] HUANG G B,ZHU Q Y,SIEW C K. Extreme learning machine:theory and applications[J]. Neurocomputing,2006,70(1/ 2/3):489-501.
- [15] ZHANG K,LUO M X. Outlier-robust extreme learning machine for regression problems [J]. Neurocomputing, 2015, 151: 1519-1527.

[16] 杨锡运,关文渊,刘玉奇,等. 基于粒子群优化的核极限学习机模型的风电功率区间预测方法[J]. 中国电机工程学报,2015,35(增刊1):146-153.
 YANG Xiyun,GUAN Wenyuan,LIU Yuqi, et al. Prediction in-

tervals forecasts of wind power based on PSO-KELM[J]. Proceedings of the CSEE,2015,35(Supplement 1):146-153.

- [17] 袁海满,吴广宁,高波. 基于DGA的粒子群极限学习机电力变 压器故障诊断[J]. 高压电器,2016,52(11):176-180,187.
 YUAN Haiman,WU Guangning,GAO Bo. Fault diagnosis of power transformer using particle swarm optimization and extreme learning machine based on DGA[J]. High Voltage Apparatus,2016,52(11):176-180,187.
- [18] 宋斌,刘志雄,李恩文,等. DGA中三比值缺码研究初探[J].
 电力自动化设备,2015,35(12):60-65.
 SONG Bin,LIU Zhixiong,LI Enwen, et al. Preliminary study of undefined three-ratio code in DGA[J]. Electric Power Automation Equipment,2015,35(12):60-65.

作者简介:



吴杰康(1965—),男,广西南宁人,教 授,博士研究生导师,主要研究方向为电力 系统运行与控制等(E-mail:wujiekang@163. com);

覃炜梅(1990—),女,广西贵港人,硕 士研究生,通信作者,主要研究方向为设备 状态评估等(E-mail:756381593@qq.com); 梁浩浩(1988—),男,重庆人,硕士研究

关杰康

生,主要研究方向为配电网管理及新技术的

应用(E-mail:715549915@qq.com);

金尚婷(1993—), 女, 河南信阳人, 硕士研究生, 主要研 究方向为电力系统运行与控制(E-mail:948979624@qq.com); 罗伟明(1993—), 男, 湖北武汉人, 硕士研究生, 主要研

究方向为设备状态评估等(E-mail:893169775@qq.com)。

Transformer fault identification method based on self-adaptive extreme learning machine

WU Jiekang, QIN Weimei, LIANG Haohao, JIN Shangting, LUO Weiming

(School of Automation, Guangdong University of Technology, Guangzhou 510006, China)

Abstract: In view of the problem of limited data processing ability and low accuracy of single intelligent algorithm when the cumulative scale and complexity of transformer state data increase, a transformer fault identification method based on self-adaptive extreme learning machine is proposed. The IA (Immune Algorithm) is used to classify the superior and inferior particle populations due to its diversity adjustment mechanism and storage mechanism, and the superior and inferior particles are evolved in different ways. The PSO (Particle Swarm Optimization) algorithm improved by IA effectively overcomes the shortcoming that the population is prone to premature development and thus leads to evolutionary stagnation, and improves the global optimization ability. On the basis of parameter optimization, the transformer fault identification model is established according to the optimization output results. The experimental results show that the fault identification accuracy of the proposed method is higher than the ELM (Extreme Learning Machine) method, the PSO-ELM (Particle Swarm Optimization-based Extreme Learning Machine) method.

Key words: power transformers; fault identification; immune algorithm; particle swarm optimization algorithm; extreme learning machine