

基于遗传算法改进极限学习机的变压器故障诊断

吕 忠¹, 周 强¹, 周 琨¹, 陈 立², 申双葵²

(1. 西南交通大学电气工程学院, 成都 610031; 2. 国网四川省电力公司成都供电公司, 成都 610041)

摘要: 针对变压器故障的特征, 结合变压器油中气体分析法以及三比值法, 提出了基于遗传算法改进极限学习机的故障诊断方法。由于输入层与隐含层的权值和阈值是随机产生, 传统的极限学习机可能会使隐含层节点过多, 训练过程中容易产生过拟合现象。该方法运用遗传算法对极限学习机的输入层与隐含层的权值与阈值进行优化, 从而提高模型的稳定性和预测精度。将诊断结果与传统的基于极限学习机故障诊断进行对比, 结果表明, 基于遗传算法改进极限学习机变压器故障诊断的精度更高。

关键词: 变压器; 三比值法; 遗传算法; 极限学习机; 故障诊断

Fault Diagnosis of Transformer Based on Extreme Learning Machine Optimized by Genetic Algorithm

LYU Zhong¹, ZHOU Qiang¹, ZHOU Kun¹, CHEN Li², SHEN Shuangkui²

(1. School of Electrical Engineering, Southwest Jiaotong University, Chengdu 610031, China;

2. State Grid Sichuan Electric Power Company Chengdu Power Supply Company, Chengdu 610041, China)

Abstract: Aiming at the characteristics of transformer fault types, a fault diagnosis method based on the improved extreme learning machine with genetic algorithm is proposed by combining with the transformer oil-dissolved gas analysis and the 3-ratio method. Because the weights and thresholds between input layer and hidden layer are generated randomly, the traditional extreme learning machine may generate excessive hidden layer nodes, resulting in over-fitting in the training process. Therefore, in the proposed method genetic algorithm is adopted to optimize weights and thresholds between input layer and hidden layer of extreme learning machine for improving the stability and prediction accuracy of extreme learning machine. Compared with the conventional fault diagnostic method based on extreme learning machine, the proposed fault diagnosis method of transformer achieves higher diagnosis precision.

Key words: transformer; 3-ratio method; genetic algorithm; extreme learning machine; fault diagnosis

0 引言

随着电力工业的快速发展, 在电力系统中越来越多的变压器投入运行, 因此有效地提高变压器故障诊断的准确率以及速度, 对电力系统的稳定运行有着重要影响。目前, 在变压器故障诊断中普遍采用色谱分析法(DGA)对变压器油中溶解的多种气体进行分析^[1-2]。基于此技术, 改良的三比值法^[3]应用广泛, 但是当在实际使用中暴露出编码不全, 编码边

界过于绝对等缺点^[4]。文[5]中采用了基于 BP 神经网络的变压器故障诊断方法。BP 算法采用梯度下降方法, 因此具有训练速度慢, 容易陷入局部极小点, 并且对学习率的选择十分敏感, 从而导致对变压器故障识别率低。文[6]中将小波神经网络引入到变压器故障诊断识别, 相比于 BP 神经网络, 具有较高的精度, 但如果小波神经网络的尺度参数和位移参数初始化不合适, 将会导致整个网络学习过程不收敛。

极限学习机 (extreme learning machine, ELM)^[7]是一种针对单隐含层前馈神经网络(SLFN)的新型算法, 该算法对网络的输入层和隐含层节点的连接权

收稿日期: 2015-01-06; 修回日期: 2015-01-27

基金项目: 国家自然科学基金高铁联合基金重点项目(U1134205); 国网四川省电力公司项目。

Project Supported by High Speed Railway Union Foundation Project in NSFC (U1134205); State Grid Sichuan Electric Power Company Project.

值以及隐含层神经元得到阈值进行随机赋值,且在训练过程中无需调整,只需调整其隐含层神经元的个数,就可以获得唯一的最优解。已经得到不少学者的关注和研究^[8-9]。但是由于 ELM 的输入层到隐含层之间的权值和阈值是随机产生的,在一定程度上导致网络结构稳定性差。如果当样本集中存在离群点时,则会导致隐含层输出矩阵存在病态^[10]。为了获得更好的泛化能力,则需要较多的隐含层节点,又会产生过拟合现象。文[11]中针对预测问题,引入基于结构风险最小化理论以及最小二乘支持向量机来克服过拟合现象。笔者提出了一种遗传算法(genetic algorithm, GA)优化的极限学习机模型(GA-ELM)从而为获得更加准确的变压器故障诊断精度。

1 基于遗传算法改进极限学习机原理

1.1 极限学习机原理

给定 N 个不同的训练样本 (x_i, t_i) , 其中 $x_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in R^n$, 即为样本的输入值, $t_i = [t_{i1}, t_{i2}, \dots, t_{im}]^T \in R^n$, 即为样本的期望输出值, 典型的单隐含层前馈神经网络见图 1。设输入层有 n 个神经元, 隐含层有 l 个神经元, 输出层有 m 个神经元, 隐含层神经元的激活函数 $g(x_i)$, 则由图 1 可知, 网络的输出为

$$y_j = \sum_{i=1}^l \beta_i g(x_i) = \sum_{i=1}^l \beta_i g(w_i \cdot x_j + b_i) \quad (1)$$

式(1)中: $j=1, 2, 3, \dots, N$; $w_i = [w_{i1}, w_{i2}, \dots, w_{in}]$ 即为输入层与隐藏层间第 i 个节点的连接权值; $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$ 即为隐藏层间第 i 个节点与输出层的连接权值; $y_j = [y_{j1}, y_{j2}, \dots, y_{jm}]$ 即为该网络的输出值。




图 1 单隐含层前馈神经网络结构

Fig. 1 SLFN structure

式(1)可以表示为

$$H\beta = Y \quad (2)$$

式(2)中, H 即为神经网络的隐含层输出矩阵, 具体形式为

$$H(w_1, w_2, \dots, w_l; b_1, b_2, \dots, b_l; x_1, x_2, \dots, x_n) = \begin{bmatrix} g(w_1 x_1 + b_1) & \dots & g(w_1 x_n + b_1) \\ g(w_2 x_1 + b_2) & \dots & g(w_2 x_n + b_2) \\ \vdots & \vdots & \vdots \\ g(w_l x_1 + b_l) & \dots & g(w_l x_n + b_l) \end{bmatrix}_{n \times l} \quad (3)$$

文[12]已经证明, 给定任意不同的样本 (x_i, t_i) , 其

中 $x_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in R^n$, $t_i = [t_{i1}, t_{i2}, \dots, t_{im}]^T \in R^n$ 。给定任意小误差 $\varepsilon (\varepsilon > 0)$ 和一个任意区间无限可微的激活函数 $g: R \rightarrow R$, 则总存在一个含有 $k (k \leq N)$ 个隐含层神经元的 SLFN, 在任意赋值 $w_i \in R^n$ 和 $b_i \in R^n$ 的情况下, 有 $\|H_{N \times M} \beta_{M \times m} - T\| < \varepsilon$ 。因此, 当激活函数 $g(x_i)$ 无限可微时, SLFN 的参数并不需要全部进行调整, w 和 b 在训练前可以随机选择, 且在训练的过程中保持不变。而隐含层与输出层间的连接权值 β 可以通过求解以下方程组的最小二乘值获得。

$$\min_{\beta} \|H\beta - T\| \quad (4)$$

其解为: $\hat{\beta} = H^+ T$ 。其中 H^+ 为隐含层输出矩阵 H 的 Moore-Penrose 广义逆^[12]。

1.2 遗传算法原理

遗传算法是以自然选择和遗传理论为基础, 将生物进化过程中适者生存规则与种群内部染色体的随机信息交换机制相结合的高效全局寻优搜索算法^[13-14]。该算法是把问题参数编码为染色体, 再利用迭代的方式进行选择, 交叉以及变异等运算来交换种群中的染色体的信息。从而使群体代代进化到搜索空间中越来越好的区域, 直至抵达最优解点^[15]。

在遗传算法中, 染色体对应的是数据或者数组, 一般由结构串数据组起来表示^[16]。串上各个位置对应基因的取值。由一系列基因组成的串就是染色体, 或者称之为基因型个体, 一定数量的个体又组成为群体, 群体中的数目称之为群体大小, 而各个个体对环境的适应程度称之为适应度。

遗传算法的主要步骤如下:

1) 初始化种群 P 。给定数据范围, 随机产生 N 个初始串数据, 为了得到高精度的权值和阈值, 采用固定长度的二进制字符串来表示个体编码^[17]。设定遗传代数、个体长度、代沟、交叉概率以及变异概率。

2) 适应度评估。将步骤 1) 中得到的染色体带入极限学习机的训练函数的权值和阈值进行训练^[18], 为了使得预测值和期望值的残差尽可能小, 所以选择预测样本的期望值和预测值的误差矩阵的范数作为目标函数的输出。

3) 选择算子。采用轮盘赌法选择算子, 即基于适应度比例的选择策略对每一代种群中的染色体进行选择。选择概率见式(5)。

$$P_i = f_i / \sum_{i=1}^P f_i \quad i=1, 2, \dots, P \quad (5)$$

4) 交叉算子。交叉算子采用单点交叉算子。

5) 变异算子。变异以一定的概率产生变异基因数, 用随机方法选出发生变异的基因。如果所选基因

的编码为 1, 则变为 0; 反之, 则变为 1。

遗传算法步骤流程图见图 2。




图 2 遗传算法流程图

Fig. 2 Flowchart of GA

综上所述, 基于 GA 优化 ELM 的变压器故障诊断的具体步骤为:

- 1) 确定 ELM 的拓扑结构。即输入层神经元个数, 隐含层神经元个数以及输出层神经元个数;
- 2) 对 ELM 中输入层到隐含层的权值以及阈值进行编码, 得到初始种群;
- 3) 解码得到权值和阈值, 将权值和阈值带入到 ELM 的训练网络中, 使用训练样本进行训练;
- 4) 训练完成后, 使用测试样本进行测试, 将测试样本的期望值和预测值的误差平方和作为适应度函数;
- 5) 对种群进行选择, 交叉, 变异, 得到新的种群, 如果满足条件, 则得出了误差平方和最小的网络权值和阈值, 如果不满足条件, 则返回步骤 2);
- 6) 将优化后的权值和阈值带入到训练网络中, 计算隐含层输出矩阵 H , 并求解矩阵 H 的 Moore-Penrose 广义逆 H^+ ;
- 7) 计算输出层权值 $\hat{\beta} = H^+T$;
- 8) 将测试样本带入到模型中进行预测。

2 实例分析

2.1 样本选取及参数设置

正常运行时, 变压器油中所含有的气体主要是氧气和氮气。当变压器发生故障时, 变压器油中含有一定量的故障特征气体, 如 CH_4 、 C_2H_6 、 C_2H_2 、 C_2H_4 、 H_2 。根据三比值法^[3], 从 5 种特征气体中选择两种溶解度和扩散系数相近的气体组分组成三对比值: C_2H_2/C_2H_4 、 C_2H_4/C_2H_6 、 CH_4/H_2 。再对这 3 对比值进行归

一化处理后作为输入矢量。因此输入层神经元个数设置为 3。文中样本采用甘肃省科学研究院中的 72 组数据^[9], 选取其中具有代表性的 30 组数据作为训练样本, 其余 42 组数据作为测试样本。同时文中采用 sigmoid 函数作为输入层到隐含层的激活函数, 将隐含层神经元个数设置为 13。将变压器的故障类型以二进制形式作为输出。把变压器的故障分为 6 种^[13], 再加上正常状态, 一共有 7 种输出, 见表 1。因此输出层神经元的个数设置为 7。

表 1 故障类型与对应神经元输出

Table 1 Fault character and its output

序号	故障类型	期望输出						
1	无故障	1	0	0	0	0	0	0
2	低温过热	0	1	0	0	0	0	0
3	中温过热	0	0	1	0	0	0	0
4	高温过热	0	0	0	1	0	0	0
5	局部放电	0	0	0	0	1	0	0
6	低能放电	0	0	0	0	0	1	0
7	高能放电	0	0	0	0	0	0	1

在使用遗传算法对极限学习机进行优化时, 需要结合极限学习机的网络拓扑结构进行一系列的参数设置^[16], 见表 2。

表 2 GA 参数设置

Table 2 GA parameter setting

参数	数值
种群大小	50.00
最大遗传代数	40.00
变量二进制位数	10.00
交叉概率	0.70
变异概率	0.01
代沟	0.95

2.2 测试分析

将样本带入到 GA-ELM 模型中对模型进行训练。其误差平方和见图 3。从图 3 中可以看出, 当进化到 26 代时, 误差平方和达到最小, 满足要求。因此将 26 代优化后的权值和阈值带入到极限学习机模型中对测试样本进行预测。为了能够进行对比分析, 同时建立未进行优化的 ELM 模型。GA-ELM 模型和 ELM 神经网络模型对变压器各类故障的诊断结果见表 3。从表 3 可以看出, GA-ELM 模型在各类故障识别的正确率均高于或者等于 ELM 模型。

GA-ELM 模型和 ELM 模型对变压器故障识别的正确率见表 4。从表 4 可以看出, GA-ELM 模型的总体故障识别正确率明显高于 ELM 模型。

同时, 为了证明 GA-ELM 算法在变压器故障诊




图3 误差进化曲线

Fig. 3 Error evolution curve

表3 GA-ELM 和 ELM 诊断结果

Table 3 Diagnosis results for GA-ELM and ELM

故障类型	GA-ELM 模型		ELM模型	
	判正台次	正确率/%	判正台次	正确率/%
无故障	7/7	100.00	5/7	71.43
低温过热	3/3	100.00	3/3	100.00
中温过热	8/8	100.00	5/8	62.50
高温过热	8/9	88.89	7/9	77.78
局部放电	2/4	50.00	2/4	50.00
低能放电	3/3	100.00	3/3	100.00
高能放电	8/8	100.00	7/8	87.50

注：判正台次为判断正确变压器台数/进行故障诊断变压器样本数。

表4 GA-ELM 和 ELM 性能比较

Table 4 Comparison of performance between GA-ELM and ELM

诊断模型	诊断正确率/%
GA-ELM	92.86
ELM	76.19

断上具有稳定性，将原来 40 组测试样本作为训练样本对网络进行训练，同时将原 30 组训练样本作为测试样本。其余参数设置不变，则 GA-ELM 和 ELM 神经网络模型对变压器各类故障诊断结果见表5。

表5 GA-ELM和ELM诊断结果

Table 5 Diagnosis results for GA-ELM and ELM

故障类型	GA-ELM 模型		ELM模型	
	判正台次	正确率/%	判正台次	正确率/%
无故障	4/4	100.00	3/4	75.00
低温过热	4/4	100.00	3/4	75.00
中温过热	5/6	83.33	4/6	66.67
高温过热	4/4	100.00	2/4	50.00
局部放电	2/4	50.00	2/4	50.00
低能放电	4/4	100.00	4/4	100.00
高能放电	4/4	100.00	3/4	75.00

当交换训练样本时，其 GA-ELM 模型和 ELM 模型对变压器故障识别的正确率见表 6。通过比较表 6 以及表 4 的诊断正确率可知，其 GA-ELM 对变压器故障诊断具有较高的精度以及稳定性。

表6 GA-ELM 和 ELM 性能比较

Table 6 Comparison of performance between GA-ELM and ELM

诊断模型	诊断正确率/%
GA-ELM	90
ELM	70

3 结语

笔者将遗传算法和极限学习机相结合，提出了一种 GA-ELM 模型，并应用到变压器故障诊断。与传统的极限学习机模型相比，GA-ELM 优化了极限学习机的输入权值与阈值，提高了变压器故障诊断的精度。仿真结果验证了该方法的准确性。

参考文献：

- [1] 刘虎威. 气相色谱方法及应用[M]. 北京: 化学工业出版社, 2000: 1-2.
- [2] LIU Huwei. Chromatography method and its application[M]. Beijing: Chemical Industry Press, 2000: 1-2.
- [3] 潘超, 马成廉, 郑玲峰, 等. 一种结合模糊 TOPSIS 法和 BP 神经网络的变压器故障诊断方法[J]. 电力系统保护与控制, 2009, 37(9): 20-24.
- [4] PAN Chao, MA Chenglian, ZHENG Lingfeng, et al. A new method based on fuzzy TOPSIS and BP neural network for power transformer fault diagnosis[J]. Power System Protection and Control, 2009, 37(9): 20-24.
- [5] 国家质量监督检验检疫总局. GB/T 7252—2001 变压器中溶解气体分析和判断导则[S]. 2002.
- [6] State General Administration of Quality Supervision, Inspection and Quarantine. GB/T 7252—2001 Transformer dissolved gas analysis and judgment guidelines[S]. 2002.
- [7] 李中, 苑津莎, 张利伟. 基于自组织抗体网络的电力变压器故障诊断[J]. 电工技术学报, 2010, 25(10): 200-206.
- [8] LI Zhong, YUAN Jinsha, ZHANG Liwei. Fault diagnosis for power transformer based on the self-organization antibody net[J]. Transactions of China Electrotechnical Society, 2010, 25(10): 200-206.
- [9] 朱浪, 王蕾, 潘丰. 基于 BP 神经网络的变压器故障诊断[J]. 江南大学学报(自然科学版), 2012, 11(3): 262-266.
- [10] ZHU Lang, WANG Lei, PAN Feng. Fault diagnosis of transformer based on BP neural network[J]. Journal of Jiangnan University(Natural Science Edition), 2012, 11(3): 262-266.

- [6] 崔东君, 刘念, 刘秀兰. 基于加权小波神经网络的油浸式电力变压器故障检测[J]. 电力系统保护与控制, 2010, 38(18): 19-23.
CUI Dongjun, LIU Nian, LIU Xiulan. Fault diagnosis of oil-immersed power transformer based on weighted wavelet neural network[J]. Power System Protection and Control, 2010, 38(18): 19-23.
- [7] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: Theory and application[J]. Neurocomputing, 2006, 70 (1/2/3): 489-501.
- [8] DENG W, CHEN L. Color imagewatermarking using regularized extreme learning machine[J]. Neural Network World, 2010, 20(3): 317-330.
- [9] ZONG Weiwei, HUANG Guangbin. Face recognition based on extreme learning machine[J]. Neurocomputing, 2011, 74 (16): 2541-2551.
- [10] TANG Xiaoliang, HAN Min. Partial lanczos extreme learning machine for single-output regression problems[J]. Neurocomputing, 2009(72): 3066-3076.
- [11] 毛力, 王运涛, 刘兴阳, 等. 基于改进极限学习机的短期电力负荷预测方法[J]. 电力系统保护与控制, 2012, 40 (20): 140-144.
MAO Li, WANG Yuntao, LIU Xingyang, et al. Short-term power load forecasting method based on improved extreme learning machine[J]. Power System Protection and Control, 2012, 40(20): 140-144.
- [12] HUANG Guangbin, CHEN Lei. Convex incremental extreme learning machine[J]. Neurocomputing, 2007, 70 (16/18): 3056-3062.
- [13] 雷英杰, 张善文, 李续武, 等. MATLAB 遗传算法工具箱及应用[M]. 西安: 西安电子科技大学出版社, 2005.
- [14] 周明, 孙树栋. 遗传算法原理及应用[M]. 北京: 国防工业出版社, 1999.
- [15] 李凤婷, 晁勤. 基于 Matlab 与遗传算法的风电容量[J]. 电工技术学报, 2009, 24(3): 178-182.
LI Fengting, CHAO Qin. Wind power capacity based on matlab and genetic algorithm[J]. Transactions of China Electrotechnical Society, 2009, 24(3): 178-182.
- [16] 史峰, 王辉, 郁磊, 等. MATLAB 智能算法 30 个案例系列分析[M]. 北京: 北京航空航天大学出版社, 2011.
- [17] 张志毅, 袁荣湘, 杨同忠, 等. 基于粗糙集和小生境遗传算法的电网故障诊断规则提取[J]. 电工技术学报, 2009, 24(1): 158-163.
ZHANG Zhiyi, YUAN Rongxiang, YANG Tongzhong, et al. Rule extraction for power system fault diagnosis based on the combination of rough sets and niche genetic algorithm[J]. Transactions of China Electrotechnical Society, 2009, 24 (1): 158-163.
- [18] 谢春娣, 梅家斌. 遗传算法在神经网络权值优化中的应用[J]. 中南民族学院学报, 2001, 20(z1): 1-3.
XIE Chundi, MEI Jiabin. The appliance of hereditary algorithm in nerve-net weights-optimizing[J]. Journal of South-Central University, 2001, 20(z1): 1-3.
- [19] 段侯峰. 基于遗传算法优化 BP 神经网络的变压器故障诊断[D]. 北京: 北京交通大学, 2008.
- 吕忠(1991—), 男, 硕士研究生, 从事电能质量分析研究。
- 周强(1989—), 男, 硕士研究生, 从事电能质量分析研究。
- (编辑 吴俊丽)

(上接第 48 页)

- damage needle model of XLPE cable[J]. High Voltage Apparatus, 2010, 46(6): 55-59.
- [15] DONNELLY K, VARLOW B R. AC conductivity effects of non-linear fillers in electrical insulation[C]//2000 Annual Report Conference on Electrical Insulation and Dielectric Phenomena.[S.l.]: IEEE, 2000: 132-135.
- [16] NIEMEYER L. A generalized approach to partial discharge modeling[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 1995, 2(4): 510-528.
- [17] GUTFLEISCH F, NIEMEYER L. Measurement and simulation of PD in epoxy voids[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 1995, 2(5): 729-743.
- [18] BODEGA R, CAVANELLI A, MORSHUIS P H F, et al. The effect of voltage frequency on partial discharge activity[C]//2002 Annual Report Conference on Electrical Insulation and Dielectric Phenomena (CEIDP). [S.l.]: IEEE, 2002: 685-689.
- [19] IEEE Std 400—2012 (revision of IEEE Std 400—2001) IEEE guide for field testing and evaluation of the insulation of shielded power cable systems rated 5 kV and above[S]. 2012: 1-54.
- [20] 杜伯学, 魏国忠. 基于小波与分形理论的电力设备局部放电类型识别[J]. 电网技术, 2006, 30(13): 76-80.
DU Baixue, WEI Guozhong. Partial discharge classification based on wavelet and fractal theory[J]. Power System Technology, 2006, 30(13): 76-80.
- 张龙(1988—), 男, 硕士研究生, 主要从事电力设备的状态检测和故障诊断方面的研究。
- (编辑 吴俊丽)