

一种基于减聚类算法和 QPSO 的 RBF 神经网络在电力变压器故障诊断中的应用

廖环宇

(南京国电南自美卓控制系统有限公司, 江苏 南京 210032)

摘 要: 本文基于油中溶解气体分析法, 采用 RBF 神经网络模型来对电力变压器进行故障诊断。为了提高诊断模型的辨识精度, 分两步对 RBF 神经网络的模型参数进行辨识: 首先采用减聚类算法, 确定 RBF 神经网络隐层基函数的中心点; 然后采用量子粒子群算法求解基函数的宽度以及输出的连接权重。仿真实验表明, 本文提出的方法具有很好的诊断效果。

关键词: 油中溶解气体法; RBF 神经网络; 量子粒子群算法; 变压器; 故障诊断

0 引言

变压器, 是电力系统中的一个关键元件, 直接影响着电力系统的稳定性与可靠性。在实际运行过程中, 一旦变压器发生严重故障或损坏, 将直接导致供电中断, 进而造成巨大的经济损失与社会影响。因此, 通过对电力变压器运行过程中的故障诊断, 及时有效的判断其状态, 对变压器的长期安全可靠运行具有重要意义。

电气预防性试验、油中溶解气体分析法(DGA)等, 都是常见的变压器故障诊断方法。DGA 是通过变压器中溶解气体的分析来判断变压器存在的故障, 实践证实 DGA 是一种变压器内部故障诊断早期诊断的有效方法。国内外根据油中气体分析和结果来判断变压器内部故障类型的方法很多, 可分为特征气体法和比值法。在我国, 目前主要沿用了 IEC 三比值法^[1], 取得了一定的成效。然而在现场应用中, 这种方法规则简单、易于实现, 然而也存在缺编码、编码边界过于绝对等问题^[2]。

近年来, 随着人工智能技术在故障诊断领域的广泛应用, 各种智能技术如模糊逻辑、神经网络等方法被引入变压器的故障诊断中, 并取得了一定的效果。如文献[3]针对信息和知识的随机性和不确定性, 构建组合贝叶斯网络进行变压器故障诊断。文献[4]结合三比值法采用 BP 神经网络对气体比值进行编码进行变压器故障的分类。文献[5]将粗糙集理论与神经网络相结合, 基于粗糙集理论简化网络结

构, 从而减少网络的训练步数, 建立相应的诊断模型。文献[6]提出了一种基于神经网络和证据理论相融合的变压器故障综合诊断方法。然而这些方法的成功应用, 取决于准确完备的先验知识经验的积累。不同的变压器, 其性能特性不尽相同, 从而其诊断及分类的知识经验也不相同, 因而上述方法很难得到大规模的推广应用。

针对这些缺点, 本文提出一种基于自适应 RBF 神经网络的电力变压器故障诊断分析方法。该方法采用 RBF 神经网络结构建立变压器的故障分析模型, 然后采用减聚类算法和量子粒子群算法(QPSO)确定 RBF 神经网络模型的参数, 并进行动态更新, 从而使诊断模型在故障诊断中具有更高的准确性。

1 诊断模型概述

本文提出的故障分析方法, 其原理如下图1所示。主要由两个模块构成。其一是RBF神经网络模型, 主要用于对实时数据进行分析, 并得出相应的分析结果; 其二是自适应的学习模块, 主要根据训练样本, 动态更新RBF神经网络模型的参数。下面分别就各个模块进行详细的阐述。

2.1 RBF 网络结构分析

RBF神经网络是由Moody和Darken于1988年最先提出^[7]。一般的RBF神经网络是典型的三层前向网络, 由输入层、隐含层、输出层组成, 其结构图如图1所示。




图 1 诊断方法总体结构框图

给定一个数据样本 $\{x_i, y_i\}_{i=1}^n$, $x_i \in \mathbb{R}^s$ 为待辨识分类的输入向量, $y_i \in \{0, 1\}$ 为输出向量。假设隐含层的神经元个数 k , 其中隐含层的激励函数 $g_j(x_i)$ 采用如式 (1) 所示的高斯函数, 从式中可以看出, 当输入信号靠近基函数中央范围时, 隐层神经元将产生较大的输出。

$$g_j(x_i) = \exp\left(-\frac{\|x_i - v_j\|_2^2}{2\sigma_j^2}\right), \begin{cases} i = 1, 2, \dots, n \\ j = 1, 2, \dots, k \end{cases} \quad (1)$$

其中 v_j 表示基函数的中心, σ_j 是基函数的宽度。

输出层神经元的激励函数是简单的线性加权函数, 因而从输入到输出的函数可以用式 (2) 进行表示。

$$y(x_i) = \sum_{j=1}^k w_j g_j(x_i) + e_i \quad (2)$$

其中 w_j 为输出层与隐层之间的连接权重, e_j 为输出偏差。

显然, RBF 神经网络待定的参数有两类: 一类是基函数的中心 v_j 、宽度 σ_j 以及中心数目 k , 另一类是输出层与隐层之间的连接权重 w_j 。通常

对于 RBF 神经网络的有两种训练方法: 一种是将所有参数基于一个优化目标函数来进行求解得到; 另一种是首先确定基函数的中心, 然后再确定相应的连接权重。第一种方法, 在于处理一些高维度的优化问题时, 对训练算法要求很高, 因此为了求解简单, 本文采用第二种训练方法。

3 减聚类算法

减聚类算法^[8]是一种无监督式的聚类算法, 可以用于确定 RBF 神经网络中的隐层基函数的中心。输入向量 $x_i \in \mathbb{R}^s$ 可以看成 s 维空间中的 n 个数据点。首先可以根据式 (3) 确定数据点 x_i 处的密度指标。

$$\rho_i^1(x_i) = \sum_{j=1}^n \exp\left[-\frac{\|x_i - x_j\|^2}{(\alpha/2)^2}\right] \quad (3)$$

其中 α 定义了该点的一个邻域半径, 该半径以外的数据点对该点的密度指标贡献甚小。在计算了每个数据点密度指标后, 选择具有最高密度指标的点作为第一个聚类中心, 用 x_c^1 表示, 相应的密度函数值为 ρ_c^1 。同时为了避免出现相距很近的聚类中心, 对每个点的密度进行修正, 如式 (4) 所示。

$$\rho_i^j(x_i) = \rho_i^{j-1}(x_i) - \rho_c^1 \cdot \exp \left[-\frac{\|x_i - x_c^{j-1}\|^2}{(\beta/2)^2} \right] \quad (4)$$

其中 $\beta = 1.5\alpha$ ，定义了一个密度指标显著减小和领域。从式中可以看出，靠近第 1 个聚类中心的数据点 x_c^1 的密度指标将显著减小。修正了每个数据点的密度指标后，然后选定下一个聚类中心 x_c^2 ，然后再次修正所有候选点的密度指标。此过程不断进行，直到满足当前最高密度指标与第一个聚类中心的密度指标比值非常小，即：

$$\frac{\rho_c^k}{\rho_c^1} < \varepsilon \quad (5)$$

由此便得到了聚类中心个数，即 k 个隐层基函数的中心 $\{x_c^1, x_c^2, \dots, x_c^k\}$ 。

4 量子粒子群优化

在确定了隐层基函数中心后，RBF 神经网络还需要确定其基函数的宽度，以及输出层与隐层的连接权重。神经网络的训练目标，是为了获得一组最优的网络参数，使得最终的网路输出逼近实际输出。显然，这是一类优化问题。对于这类优化问题，粒群算法由于其原理简单、实现容易，得到了广泛的应用。

粒子群算法，是 Kennedy 和 Eberhart 于 1995 年共同提出^[9]。这是一种模拟鸟群觅食行业的一种群体智能优化算法。基本思路是：假设在一个 N 维的目标搜索空间中， m 个粒子组成一个群体 $X = \{X_1, X_2, \dots, X_m\}$ ，在 t 时刻第 i 个粒子的位置表示为 $P_i(t) = [P_{i1}(t), P_{i2}(t), \dots, P_{iN}(t)]$ ，根据目标函数计算得出 P_i 的适应度。个体的最好位置表示为 $Pb_i(t) = [Pb_{i1}(t), Pb_{i2}(t), \dots, Pb_{iN}(t)]$ ，群体的全局最好位置为 $Gb_i(t) = [Gb_{i1}(t), Gb_{i2}(t), \dots, Gb_{iN}(t)]$ 。第 i 个粒子的速度表示为 $V_i(t) = [V_{i1}(t), V_{i2}(t), \dots, V_{iN}(t)]$ ，每次迭代粒子通过

式 (6) 和式 (7) 不断更新自己的位置和速度。

$$\begin{aligned} V_{id}(t+1) &= V_{id}(t) + c_1 R_1 [Pb_{id}(t) - P_{id}(t)] \\ &\quad + c_2 R_2 [Gb_{id}(t) - P_{id}(t)] \end{aligned} \quad (6)$$

$$P_{id}(t+1) = P_{id}(t) + V_{id}(t+1) \quad (7)$$

其中 $d = 1, 2, \dots, N$ 是空间的维数， $d = 1, 2, \dots, m$ 为种群个数， R_1 和 R_2 为介于 (0,1) 区间的随机数， C_1 和 C_2 为加速常数。

基本的粒子群算法，粒子的运动状态由位置与速度来描述，随着时间的演化，粒子运动的轨迹是既定的，同时粒子的速度受到一定的限制，因而其搜索的空间是一个有限的区域，不能覆盖整个可行空间，所以不能以概率 1 全局收敛。为了提高变压器故障诊断模型的精度，本文采用一种量子粒子群算法来求解 RBF 神经网络中基函数的宽度和输出层与隐含层的连接权重。量子粒子群算法主要基于微观粒子所具有的波动—粒子二象性。在量子空间中，每个粒子都受到空间中存在的某种形式的吸引势能的束缚，从而产生一种聚集性，而被束缚的粒子可以一定的概率密度出现在空间任意点，因此该粒子可以在整个可行解空间中进行搜索，从而具有更好的全局搜索性能。

与基本粒子群算法相比，量子粒子群算法主要的不同点在于其状态描述方法，以及状态更新方法。在量子空间中，粒子的状态通过所谓的波函数 $\phi(Y)$ 来进行描述，如式 (8) 所示。

$$\phi(Y) = \frac{1}{\sqrt{L}} e^{-\frac{|Y|}{L}} \quad (8)$$

其中， $L = \frac{1}{\beta} = \frac{h^2}{mr}$ 为粒子出现在相对点的概率。

对 N 维空间，设吸引子

$$p_i(t) = [p_{i1}(t), p_{i2}(t), \dots, p_{iN}(t)] \quad , \quad \text{分量}$$

$$p_{id}(t) = \varphi \cdot Pb_{id}(t) + (1 - \varphi) \cdot Gb_{id}(t) \quad , \quad \text{其中 } \varphi \text{ 为 } [0, 1]$$

上均匀分布的随机数。采用蒙特卡洛方法，粒子的位置可以表示为：

$$P_{id}(t+1) = p_{id}(t) \pm \frac{L_{id}(t)}{2} \ln \frac{1}{u_{id}(t)} \quad (9)$$

式中, u 为[0, 1]上均匀分布的随机数, $L_{id}(t)$ 可以由下式确定

$$L_{id}(t) = 2\beta |mbest - P_{id}(t)| \quad (10)$$

其中 β 为收缩扩张系数, $mbest$ 定义为平均最好位置, 其表达式如下

$$mbest = \frac{1}{m} \sum_{i=1}^m p_i(t) = \frac{1}{m} \left[\sum_{i=1}^m p_{i1}(t), \sum_{i=1}^m p_{i2}(t), L, \sum_{i=1}^m p_{iN}(t) \right] \quad (11)$$

则相应的位置方程改写为

$$P_{id}(t+1) = p_{id}(t) \pm \beta |mbest - P_{id}(t)| \ln \frac{1}{u_{id}(t)} \quad (12)$$

综上所述, 量子粒子群算法的计算步骤如下:

Step 1: 初始化种群规模 m 和最大迭代次数

MaxGen。随机产生 m 个粒子的种群, 计算初始的全局最优位置和每个粒子的个体最优位置。

Step 2: 计算出每个粒子的适应度, 并与该粒子的个体最优的适应度比较, 如果当前适应度小于个体最优适应度, 则该个体最优位置更新为当前位置。

Step 3: 计算当前全局最优位置, 并与前一次迭代的全局最优位置进行比较, 如果当前全局最优位置较好, 则全局最优位置更新为当前值。

Step 4: 根据式 (11) 计算粒子群的平均最优位置。然后根据 (12) 更新粒子的位置。

Step 5: 判断迭代结束条件, 如满足则退出迭代过程, 输出结果, 否则转至 Step 2)。

5 仿真分析

变压器的运行状态可以分为正常态和故障态, 而故障态又可以分为: 过热、高能量放电、低能量放电三种情况。在故障发生时, 油中溶解气体 (主要包括 H_2 、 CH_4 、 C_2H_2 、 C_2H_4 、 C_2H_6) 的成分也会发生相应的变化, 因此输入特征向量

$X = \{x_{H_2}, x_{CH_4}, x_{C_2H_2}, x_{C_2H_4}, x_{C_2H_6}\}$ 。输出向量为

$Y = \{y_1, y_2, y_3\}$, 其中 $y_i = \{0, 1\}$ 。 $y_1 = 1$ 表示过热故障发生, 反之表示不发生; $y_2 = 1$ 表示高能量放电故障发生, 反之表示不发生; $y_3 = 1$ 表示低

能量放电故障发生, 反之表示不发生。

文献[10]中所记录的国内某 500kV 变压器处于不同状态下的 75 组数据, 各种状态下所包含的数据个数如表 1 所示。

表 1 变压器运行状态数据集信息

状态	个数
正常态	9
过热	38
低能量放电	11
高能量放电	17

同时为了比较本文提出方法的优越性, 在仿真过程中, 将本文提出的方法与传统的三比值法, 及基于基本 PSO 的 RBF 神经网络诊断方法进行比较, 其结果如 2 所示, 从中可以看出, 本文提出的方法明显优于传统的三比值法和基于基本 PSO 的 RBF 神经网络方法。

表 2 仿真结果比较

诊断方法	正常态 正确率 /%	过热态 正确率 /%	低能量放电 态正确率 /%	高能量 放电态 正确率/%	总正确率 /%
三比值法	66.67	78.95	54.55	76.47	73.33
PSO-RBF	77.78	86.84	72.73	88.24	84
QPSO-RBF	88.89	92.11	81.82	94.12	90.67

6 结束语

本文提出了一种基于自适应 RBF 神经网络的变压器故障诊断方法。该方法建立 RBF 神经网络诊断模型, 并通过减聚类算法和量子粒子群算法对 RBF 神经网络的模型能数进行自动配置。仿真实验表明, 本文所提出的 RBF 神经网络训练算法能很好的改善网络性能, 能有效诊断出变压器故障, 并比传统的方法相比, 具有更高的诊断正确率。

参考文献:

- [1] GB/T 7525-2001, 变压器油中溶解气体分析和判断导则[S].
- [2] Y.C. Liang, X.Y. Sun, D.H. Liu. Application of combinatorial probabilistic neural network in fault diagnosis of power transformer[C]. International Conference on Machine Learning and Cybernetics, 2007: 1115-1119.
- [3] 赵文清, 朱永利, 王晓辉. 基于组合贝叶斯网络的电力变压器故障诊断[J]. 电力自动化设备, 2009, 29(11): 6-9.
- [4] 杜文霞, 吕锋, 句希源. 基于 BP 神经网络的电力变压器故障诊断[J]. 变压器, 2007, 44(3): 45-47.
- [5] 梁永春, 李彦明. 改进型组合 RBF 神经网络的变压器

- 故障诊断[J]. 高电压技术, 2005, 31(9): 31-33.
- [6] 俞晓科, 马凤英, 臧宏志. 粗糙集理论与神经网络在变压器故障诊断中的应用[J]. 继电器, 2005, 34(1): 10-15.
- [7] J. Moody, C. Darken. Fast learning in networks of locally-tuned processing unit[J]. Neural Competition, 1989, (1): 281-294.
- [8] S.L. Chiu. Fuzzy model identification based on cluster estimation[J]. Journal of Intelligent and Fuzzy system, 1994, 2(3): 267-278.
- [9] J. Kennedy, R.C. Eberhart. Particle swarm optimization[J]. IEEE International Conference on Neural Networks, 1995, 4: 1942-1948.
- [10] G.Y. Lv, H.Z. Cheng, H.B. Zhai, and L.X. Dong. Fault diagnosis of power transformer based on multilayer SVM classifier[J]. Electrical Power System Research, 2005, 74(1): 1-7.

作者简介:

廖环宇 (1985—), 男, 湖南衡阳人, 工程师, 主要从事控制理论与应用、SCADA 监控、电厂 DCS 系统的研发工作。

A RBF neural network based on subtractive clustering method and QPSO for the fault diagnosis of power transformer

LIAO Huan-yu

(Nanjing SAC & Metso Control System Co., Ltd, China)

Abstract: This paper adopted a RBF neural networks model for the fault diagnosis of power transformer, based on the dissolved gas analysis method. In order to improve the performance of the diagnosis model, a two-stage method was proposed to identify the parameters of the RBF neural networks. First, centers of the hidden layer activated functions were determined by subtractive clustering method. Then, radii of hidden layer activated and output connection weights were automatically calculated through quantum-behaved particle swarm optimization algorithm. The simulation showed that the method proposed in this paper is feasible.

Key words: dissolved gas analysis(DGA); RBF neural network; quantum-behaved particle swarm; transformer; fault diagnosis.