

基于自组织特征映射神经网络的高压断路器故障诊断

高压断路器在电力系统中起到了控制、保护、配电和监视等作用，是重要的电力设备，其运行可靠性对电力系统安全、稳定运行具有重要意义。在建立高压断路器故障诊断模型及其运行状态特征参量选取的基础上，利用自组织特征映射（Self-Organizing feature Map, SOM）神经网络在模式聚类中的优越性，实现高压断路器的故障诊断。

张好勇 张东亮 高树军 张 华/国网廊坊供电公司

0 引言

作为电力系统中重要的电力设备，高压断路器承担着保护和控制作用，其运行可靠性是电力系统能否稳定运行的关键所在。在全球能源互联网的发展和推动下，智能电网和电网全球互联是电网今后发展面临的新课题和新挑战，因而这就对高压断路器运行可靠性提出更高的要求。目前，主要是通过提高加强断路器的检修与维护来保证断路器的运行可靠性。传统的检修方式是根据断路器设备运行周期定期进行计划检修，这在一定程度上保证了电网安全稳定运行，但这种检修方式存在检修工作量大、费用高、检修过剩或检修不足等缺陷。因此，根据断路器在实际运行状态下的技术参数和特性分析判断是否进行检修的状态检修应运而生，状态检修不仅能够避免因计划检修而产生的停电时间、减小工作量及降低维护费用，而且提高了检修的针对性，大大提高断路器运行的可靠性和经济性，但其对断路器在线监测和故障诊断技术提出了新的要求。

目前，对于高压断路器的故障诊断多采用模糊理论^[1-3]、RBF神经网络^[4-5]、概率神经网络^[6]和BP神经网络等算法。其中采用较多的是BP神经网络，但BP神经网络算法存在收敛速度慢、隐含层和隐节点个数难以确定、学习过程可能陷入局部最小值等缺点。而自组织特征映射神经网络是一种无监督学习的聚类算法，它不但能够学习输入向量在输入空间的分布情况，而且能够学习输入向量的拓扑结构，并将形成的聚类中心映射到一个曲面或平面上且保持拓扑结构不变，因而在模式识别、聚类等方面得到了广泛的应用。

1 高压断路器故障诊断模型

1.1 高压断路器运行状态特征参量的选取

要实现高压断路器的故障诊断，首先要对其进行实际工况运行状态下各个特征量的监测^[7-8]，表1列出了断路器在工况下常用的状态特征参量。

表1 状态特征参量

监测元件	状态特征参量
分/合闸线圈	电压、电流
储能电动机	电压、电流
动触头	分合闸时间、速度和行程

根据国际大电网会议对高压断路器的故障统计和分析表明，断路器故障中有70%~80%是由其操动机构故障引起的。高压断路器操动机构主要包括储能电动机、分/合闸线圈和继电器等元件，本文以分/合闸线圈电流为特征参量说明



张好勇/工程师

关键词/Keywords

高压断路器 ·
自组织特征映射神经网络 ·
特征参量 ·
故障诊断 ·

高压断路器操动机构的故障诊断。

1.2 基于分/合闸线圈的故障诊断模型

分/合闸线圈是高压断路器操动机构的重要组成部分，其通过驱动分合闸电磁铁实现断路器的分合闸操作。因此，通过对分/合闸线圈中电流监测，能够反映铁心行程、操作电压、操动机构和辅助开关等元件的工作状态。

分/合闸线圈回路的等效电路^[9]如图1所示。




图1 分/合闸线圈回路等效电路

假设分/合闸线圈电磁铁不饱和，则线圈中电压与电流之间的关系可用式(1)表示，即

$$U = Ri(t) + \frac{d(Li)}{dt} \quad (1)$$

式中， U 为线圈两端直流恒压电源； L 为线圈等效电抗； R 为线圈自身电阻。由式(1)可得到断路器分/合闸线圈在操作过程中的电流波形如图2所示。




图2 分/合闸线圈电流波形

从图2可以看出，分/合闸电磁铁心运动可以分为五个阶段。

1) $t_0 \sim t_1$ 阶段。 t_0 时刻，线圈得电，线圈电流以指数形式增长， t_1 时刻线圈电磁铁心开始运动。

2) $t_1 \sim t_2$ 阶段。受线圈中反电动势的影响，线圈电流在此阶段开始降低， t_2 时刻，线圈电磁铁心结束运动。

3) $t_2 \sim t_3$ 阶段。断路器在此阶段完成分/合闸操作，由于线圈中反电动势消失，电流继续以指

数形式增大。

4) $t_3 \sim t_4$ 阶段。此阶段为断路器完成分/合闸操作后和线圈回路开断前之间的短暂稳态阶段，线圈电流趋于稳定。

5) $t_4 \sim t_5$ 阶段。断路器分/合闸回路在此阶段完成开断工作，开断过程中，受辅助开关触头间电弧电压的影响，线圈电流急速下降，直至为零。

由上述分析可以看出，通过对断路器分/合闸线圈电流 t_1 、 t_2 、 t_3 、 t_4 、 t_5 、 I_1 、 I_2 和 I_3 等八个特征参数的选取，判断断路器是否存在线圈老化、机构卡涩及操作电压过低等缺陷。

2 自组织特征映射神经网络

2.1 自组织特征映射神经网络理论

自组织特征映射(Self-Organizing feature Map, SOM)神经网络^[10-13]是由芬兰赫尔辛基大学神经网络专家Kohonen教授在1981年提出的。SOM神经网络是一种无监督学习型网络，不但能够学习输入向量的空间分布，同时还能够学习输入向量的拓扑结构，是很好的模式聚类型网络。

SOM神经网络结构由输入层和竞争层构成，如图3所示。




图3 SOM神经网络结构

假定网络输入为 $X \in R^n$ ，则竞争层神经元输出 O_i 为

$$O_i = \sigma \left[\varphi_i + \sum_{t \in S_t} r_k O_t \right] \quad (2)$$

$$\varphi_i = \sum_{j=1}^m w_{ij} x_j$$

式中， w_{ij} 为输出神经元 i 和输入神经元 j 之间的连接权值； x_j 为输入神经元 j 的输出； σ 为时间 t 的非

线性函数。

输入层和竞争层神经元之间采取全互连接，且其连接权由神经元对输入模式反应的连接权和神经元之间的连接权两部分组成，后者控制着竞争获胜神经元邻域单元 N_c 的大小。

2.2 SOM神经网络学习算法流程

SOM神经网络学习流程如图4所示。

- 1) 数据预处理。将输入样本数据进行归一化，使其位于同一取值范围内。
- 2) 初始化。对网络连接权值 w_{ij} 、学习速率 η_N 、邻域 N_c 以及训练步数 T 进行初始赋值。
- 3) 通过计算输入层神经元与输竞争层全部神经元之间连接权向量 w_{ij} 的欧式距离，确定竞争层获胜单元。
- 4) 修正竞争获胜神经元及其邻域神经元的连接权值。
- 5) 调整网络学习速率和邻域宽度，直至网络学习结束。




图4 SOM算法学习流程

3 基于SOM神经网络的高压断路器故障诊断实验仿真与分析

基于SOM神经网络的高压断路器故障诊断

首先需要将能够反映断路器故障的样本数据进行SOM神经网络训练学习，确定各类故障对应的竞争层获胜单元及其邻域单元，然后将待诊断数据作为网络输入进行故障诊断。其故障诊断流程如图5所示。




图5 SOM算法故障诊断流程

本文以图2为故障诊断模型，通过在线监测方法采集了某型号10 kV断路器共20组故障样本数据，如表2所示。

表2 故障样本数据

故障类型	铁心卡涩	操作电压过低	操动机构卡涩	铁心空程过长
样本数据	5组特征参量	5组特征参量	5组特征参量	5组特征参量

本文取每种故障类型的4组特征参量进行SOM神经网络训练，1组特征参量作为待诊断样本进行故障诊断。SOM神经网络竞争层神经元结构设置为 $[5 \times 6]$ ，初始学习速率 η_{N0} 为0.45，神经元初始邻域宽度 d_0 为1/3竞争层宽度。其训练结果与故障诊断结果如6所示。




图6 SOM神经网络

由图6a可以看出，表2给出的20组样本数据经SOM神经网络训练后，故障样本数据成功得到分类，相同的故障类型的故障数据由同一种颜色表

示, 红色为线圈铁心卡涩, 青色为线圈两端电压过低, 粉色为操动机构卡涩, 棕色为线圈铁心空行程过长, 且给出每个神经元在训练过程中作为竞争获胜单元的次数。

图6b给出了通过图6a训练好的SOM神经网络对待诊断样本数据进行故障诊断的结果。可以看出, 诊断过程中, 四组不同故障类型的待诊断样本数据均落在对应的故障类型区域, 即本次训练的SOM网络故障诊断正确率为100%, 能够准确地实现高压断路器的故障诊断。且SOM神经网络训练过程和诊断过程仅用时0.01 s, 相较于RBF神经网络、概率神经网络及BP神经网络等算法具有较快的收敛速度, 保证了高压断路器故障诊断的准确性、高效性。

4 结束语

本文以高压断路器分/合线圈电流为故障诊断模型, 介绍了基于SOM神经网络的高压断路器故障诊断方法。通过实验证明, SOM神经网络建模过程简单, 收敛速度快, 网络训练可视化, 且能够准确地对输入故障模式进行分类和故障诊断, 为高压断路器在线故障诊断提供了一种新的途径。但在实际工程应用中, 通过高压断路器在线监测装置采集到的特征参量均是高维数据, 且高维数据中存在非特征元素, 在一定程度上影响网络收敛速度, 因此, 需要对高维数据进行主元分析, 将高维数据投影到低维空间。下一阶段, 笔者将对改进的PCA-SOM神经网络进行学习和研究。

参考文献

- [1] 黄凌洁, 王玮, 吴振升, 等. 基于模糊理论的高压断路器故障诊断模型的研究 [J]. 高压电器, 2008, 44 (3): 246-249.
- [2] Pan Y, Chen J, Li X. Bearing performance degradation assessment based on lifting wavelet packet decomposition and fuzzy c-means [J]. Mechanical Systems and Signal Processing, 2010, 24 (2): 559-566.
- [3] 陈伟根, 李伟, 陈新岗. SF₆高压断路器状态分析的模糊综合评判方法 [J]. 高压电器, 2004 (5): 361-363.
- [4] 程勇, 蔡文凤, 罗小安. 基于正交算法的RBF网络在高压断路器故障诊断中的应用研究 [J]. 中国电机工程学报, 2007 (3): 95-99.
- [5] 骆平, 范瑜. 基于RBFNN的高压断路器机械故障诊断系统 [J]. 中国电力, 2010, 43 (5): 30-34.
- [6] 吴浩, 李群湛, 夏焰坤, 等. 基于概率神经网络的广域后备保护故障判别研究 [J]. 电力系统保与控制, 2012, 40 (7): 43-49.
- [7] 胡晓光, 孙来军. SF₆断路器在线绝缘监测方法研究 [J]. 电力自动化设备, 2006 (4): 1-3.
- [8] 陈剑光. 无接触式真空断路器电寿命在线监测系统研究 [D]. 保定: 华北电力大学, 2013.
- [9] 张永奎, 赵智忠, 冯旭, 等. 基于分合闸线圈电流信号的高压断路器机械故障诊断 [J]. 高压电器, 2013, 49 (2): 37-42.
- [10] 张德丰. Matlab神经网络仿真与应用 [M]. 北京: 电子工业出版社, 2009.
- [11] 吴雪茹. 基于自组织网络的故障诊断算法改进及可视化研究 [D]. 武汉: 湖北工业大学, 2012.
- [12] Cheng G, Cheng Y-L, Shen L-H, et al. Gear fault identification based on Hilbert-Huang transform and SOM neural network [J]. Measurement: Journal of the International Measurement Confederation, 2013, 46 (3): 1137-1146.
- [13] Qiu H, Lee J, Lin J, et al. Robust performance degradation assessment methods for enhanced rolling element bearing prognostic [J]. Advanced Engineering Informatics, 2003, 17 (3-4): 127-140.

(收稿日期: 2016-07-10) EA