

基于 Kohonen 网络的同杆双回线故障模式识别方法

郭付军, 林军

(福州大学电气工程系, 福建 福州 350002)

摘要: 对模式识别能力较强的 Kohonen 自组织神经网络及其在同杆双回线的故障模式识别方面的应用作了一些初步的讨论和研究, 发现该网络能准确可靠识别发生在除母线附近外的双回线路上的所有故障模式, 分析了线路两端故障模式误判的原因并提出了改进措施, 指出了 Kohonen 网络应用于同杆双回线故障模式识别时的优点和局限性。

关键词: Kohonen 神经网络; 同杆双回线; 模式识别

中图分类号: TM733 **文献标识码:** A **文章编号:** 1003-4897(2002)04-0004-04

1 引言

电力系统单回线路故障模式较少, 共 11 种, 选用适当的特征量组合可以对这些故障进行准确的识别。文献[1]用 Kohonen 神经网络对单回线的故障模式识别作了研究。同杆双回线故障模式达 120 种, 这些故障中, 按故障是否跨线划分则跨线故障模式约占 82%, 按故障是否接地划分则接地故障模式占 52.5%。尽管故障模式繁多, 但同杆双回线上频繁发生的不是两回线之间的跨线故障, 而是单回线路上的故障, 其发生机率在 80% 以上。因为存在回路之间的互感及其它复杂因素的影响, 用传统方法如解析判式和设置门槛值等方法进行同杆双回线的故障模式识别有时会失效, 原因是线路故障模式在空间分布上不是线性可分的。本文对模式识别能力较强的 Kohonen 自组织网络及其在同杆双回线的故障模式识别方面的应用作了一些讨论和研究。

2 Kohonen 网络

Kohonen 网络采用无导师学习制, 网络权值根据输入训练样本进行自适应、自组织地逐渐收敛到样本空间内需划分到的子集中心, 训练成功后的网络具有对样本的记忆和联想能力, 可以实现对输入信号的分类。

如图 1 所示为 Kohonen 网络, 网络输入层单元数 N 由分类所用的特征量的数目确定, Kohonen 层即输出层单元数 K 由分类结果的数目确定。设网络训练样本数为 M , 学习率为 η , 邻域为 N_r 。本文采用以下参数设置和步骤训练网络:

1) 输入数据的规格化: $x = \frac{x - x_{\min}}{x_{\max} - x_{\min}} (a_{\max} -$

$a_{\min}) + a_{\min}$, 其中待规格化数为 x , 输入数据的最大值为 x_{\max} , 最小值为 x_{\min} , 网络允许输入数据的最大值为 a_{\max} , 最小值为 a_{\min} , 规格化结果为 x ;

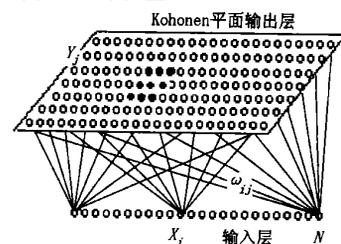


图 1 Kohonen 神经网络

- 2) 网络初始权值取随机数: $w_{ij} = \text{rand}(a_{\min}, a_{\max}), i = (1, N), j = (1, K)$;
- 3) 取经规格化的样本集中的一个输入向量 $X = (x_1, x_2, \dots, x_N)$;
- 4) 计算 $d(X, j) = \|X - j\| = \sqrt{\sum_{i=1}^N (x_i - w_{ij})^2}, j = 1 \dots K$;
- 5) 求取 $d_{j_0} = \min d(X, j), j = (1, K)$, d_{j_0} 所在的获胜单元为 j_0 ;
- 6) 邻域 $N_r \subseteq \min \text{dis}(j_0, l), l = j_0, l = (1, K)$;
- 7) 修改权向量: $w_j^{t+1} = w_j^t + \eta(t)(X - w_j^t), j = (1, K)$, 其中 t 表示权值修改次数, $\eta(t)$ 称为学习率, 其求法根据具体情况确定, 此处取:

$$\eta(t) = \begin{cases} 0.10(1 - t/M), & j = j_0 \\ 0.01(1 - t/M), & j = N_r \\ 0, & j \notin N_r, j = j_0 \end{cases}$$
- 8) 回到第 3) 步进行下一个样本的训练;
- 9) 结束训练的条件为: $\max(|w_j^{t+1} - w_j^t|) < \epsilon$ 或 $t = M$ 使网络趋于稳定。

3 仿真系统

本文用 Kohonen 网络就图 4 所示的系统进行了故障模式识别仿真, x 表示故障距离, $L = 600\text{km}$ 为线路全长(这样的系统是存在的,如山西阳城至江苏的一条同杆双回线路,其电压为 500kV , $L = 750\text{km}$)。图 2 中避雷线的半径为 7.24mm , 交流电阻为 $0.374 / \text{km}$, 输电线的半径为 11.85mm , 交流电阻为 $0.026 / \text{km}$;图 3 中每回线路有两个完整换位。如当故障距离 $x = 110\text{km}$ 、 $L = 600\text{km}$ 、故障电阻 = 10 且 a 相接地短路时 M 侧电流电压分别为:

$$\begin{aligned} i_a &= 1.426929 - j3.653221\text{kA} \\ i_A &= -0.542471 + j0.340517\text{kA} \\ i_b &= 0.464228 + j0.303375\text{kA} \\ i_B &= 0.479683 + j0.270566\text{kA} \\ i_c &= 0.052020 - j0.599315\text{kA} \\ i_C &= 0.036865 - j0.614032\text{kA} \\ u_a &= u_A = 179.712363 - j38.893315\text{kV} \\ u_b &= u_B = -173.128137 - j258.378682\text{kV} \\ u_c &= u_C = -174.254889 + j240.342435\text{kV} \end{aligned}$$

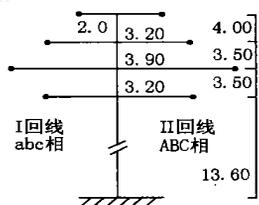


图 2 双回线排布方式

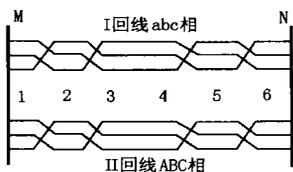


图 3 双回线换位方式

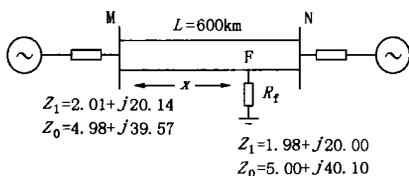


图 4 500kV 系统示意图

4 训练网络

训练网络之前首先要确定区分各种故障模式的特征量组合以及总的样本集,之后才能按一定的步

骤来训练 Kohonen 网络。特征量和样本集的优劣决定着网络的性能。

特征量的选取以其组合数目最小且能准确可靠区分所有故障模式为原则。本文先试探性地用 M 侧的单侧电压电流的基频分量为特征量来训练网络,电压电流用实部和虚部的格式表示,且以 I 回线路的 a 相电压为基准值。

选定特征量后,就要确定总的训练样本集。样本集的确定以训练数据中包含有各种应有的故障模式为原则,尤其在模式的边界处,应有较多的训练数据,以保证网络对各种模式有清晰的分辨能力。一个特征量组合构成一个样本,考虑下列各因素后的所有特征量组合构成总的训练样本集(其它因素如参考相角和电势夹角等暂且不考虑):

- 1) 故障距离 x 从母线 M 处开始以 50km 为步长递增至母线 N 处,且在 M 和 N 处减小步长;
- 2) 故障电阻 R_f 分别取 $0, 40, 80$;
- 3) N 端系统阻抗分别取 $0.7, 1.0, 1.3$ 倍的额定阻抗。

从样本集中随机提取样本按前面的 Kohonen 网络训练步骤对其训练。注意在训练网络时样本的提取是随机的,这样可以避免网络在局部早熟。所有样本训练完后应对部分样本重新训练。如果训练完成后网络不收敛,则应增大样本集的容量或重新选取特征量。

5 结果分析

用独立于样本集的数据对训练好的网络进行检验,有以下结果:

- 1) 当 $50\text{km} < x < 550\text{km}$ 时网络能够正确识别所有故障模式;
- 2) 当 $x > 550\text{km}$ 时在 550km 附近网络不能区分正常运行状态和 a-A、b-B、c-C 相间短路故障,靠近 N 端时网络不能正确区分所有故障模式;
- 3) 当 $x < 50\text{km}$ 时在 50km 附近网络不能区分正常运行状态和 a-A、b-B、c-C 相间短路故障,不能区分部分单相接地故障和跨线相间短路接地故障,靠近 M 端时网络不能正确区分所有故障模式;
- 4) 当线路的运行条件发生很大的变化时(即线路实际运行数据大大偏离网络训练样本集),网络也存在误判。

从以上几点可以看出, Kohonen 网络在线路中间很大的区间内能正确进行故障模式识别,但在母线 M 和 N 的附近区域存在模式误判,进一步分析发现

误判的大多为跨线故障模式。这是因为在 500kV 的高压线路上,分布电容起着不可忽视的充电作用,同时双回线路经两个完整换拉后,在线路末端因线路参数不平衡而产生的不平衡电流已经相对很小,从而 a-A、b-B、c-C 三种同名相间短路故障表现为 M 侧电压电流时与正常运行状态已经很难区分。其它发生在线路末端的故障误判也有类似的原因。在线路首端,故障时 M 处母线电压电流取值相对线路末端变化很大,如正常运行时 M 处 a 相电流为 $-0.50 + j0.25\text{kA}$, 10km 处 a 相单相接地故障时 M 处 a 相电流为 $3.553966 - j7.461572\text{kA}$, 550km 处 a 相单相接地故障时 M 处 a 相电流为 $0.261153 - j0.739672\text{kA}$ 。从理论上讲,特征量相差越大,区别不同模式的应该越容易,但对 Kohonen 网络并不完全正确,原因有二:

1) Kohonen 网络其实用的是一种最佳邻近匹配原则,从训练网络时求取模式与权值之间的距离公式 $d(X, j) = |X - j| = \sqrt{\sum_{i=1}^N (X_i - j_{ij})^2}$, $j=1 \dots K$ 可以看出,尽管所有的数据经过规格化处理,但处理后的输入数据分量与其对应的权值分量作差后,不同分量的差值在数值上相差还是比较大,从而使大的差值淹没了小的差值,即小的差值对距离值的贡献被忽略,从而造成模式误判。因此,造成误判的原因之一是在识别相近模式时起关键作用的特征量分量其作用在距离公式中被淡化;

2) Kohonen 网络是双层网,没有隐含层,记忆能力差,在学习别的样本时,把已学过的样本淡忘了,甚至遗忘了。

6 改进措施

针对前面不同的故障模式误判情况,提出如下的改进措施:

1) 将模式与权值间的距离公式改为 $d(X, j) = \sum_{i=1}^N |X_i - j_{ij}|$, $j=1 \dots K$, 即将平方项换为绝对值项,这样可以减小大的分量差值淹没小的分量差值的程度(尽管该公式在多维空间上不认为有“距离”意义,但在此处相对原公式有较好的仿真效果);

2) 将网络允许输入数据的范围从 $a_{\max} = 1.00$ 和 $a_{\min} = 0.00$ 变为 $a_{\max} = 10.00$ 和 $a_{\min} = 1.00$, 这样做是为了避免浮点数运算时的舍入误差;

3) 同杆双回线发生故障时,不同相别的电压电流取值相差很大,特征量数据规格化时所有电压的实虚部取同一对上下限,所有电流的实虚部取另一对上下限,这样做会人为地造成某些数据总是偏大

而另一些总是偏小,改进的办法是对特征量的每个分量规格化时取适合该分量的上下限;

4) 增加母线 M 和 N 附近样本的密度;

5) 特征量决定着网络的性能,因此最有效的改进措施是增加特征量个数,选取新的特征量组合,从不同域(时域和频域)提取特征量分量:增加特征量个数是为了弥补 Kohonen 网络记忆能力差的缺点,除了电压电流基频分量外,还可以增加电压电流的负序分量和零序分量以及直流分量;选取新的特征量组合是因为电压电流基频分量并不一定是最佳的,其中某些特征量分量的作用并不明显,负序分量、零序分量和直流分量可以明显区分不同的非对称故障模式。

经过以上改进措施重新训练后的 Kohonen 网络能在更大的区间上进行准确的故障模式识别,但在线路两端靠近母线 M 和 N 处仍存在很小的故障模式误判区间,对于此问题,作如下处理:

可以将故障识别与故障测距放在同一算法中共同完成,如图 5 所示为一故障识别与测距的集成网络模型,加入 BP 网络是因为该网有较强的记忆能力,在线路运行条件变化很大时也能适应,但测距精度较差, Kohonen 网记忆力差,却有较强的局部识别能力。仿真表明,将二者结合,可以同时得到很佳的故障识别与测距结果。

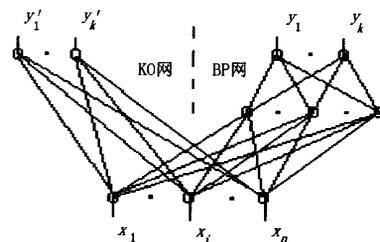


图5 集成聚类网络

7 结论

同杆双回线因其故障模式繁多,某些故障模式表现为单侧母线处的特征量时相差甚微,这增加了故障模式识别的难度。Kohonen 自组织网络有很好的模式识别能力,能准确识别同杆双回线上很大区间内的所有故障模式,但因该网络是双层网,没有隐含层,记忆能力差,导致训练后的网络不能正确识别母线附近的部分故障模式。

参考文献:

- [1] Chowdhury B H, Wang Kunyu. Fault Classification Using Kohonen Feature Mapping[C]. Proceedings of the Conference on Intelligent System Applications to Power System. USA, 1996, 194-198.
- [2] 张际先. 神经网络及其在工程中的应用[M]. 机械工业出版社, 1996.

- [3] 索南加乐. 同杆双回线的六序选相原理[J]. 中国电机工程学报, 1991, 11.

收稿日期: 2001-09-30; 修回日期: 2002-03-09

作者简介: 郭付军(1976-), 男, 研究生, 研究方向为电力系统及其自动化; 林军(1959-), 男, 副教授, 从事电力系统微机保护、故障测距等研究与教学工作。

A method of fault pattern recognition on same-tower double-circuit lines using Kohonen neural network

GUO FuJun, LIN Jun

(Dept. of Electric Engineering, Fuzhou University, Fuzhou 350002, China)

Abstract: This paper gives an introduce of Kohonen neural network and its use in fault pattern recognition on same-tower double-circuit lines, finding out the neural network works well at recognizing all fault patterns on all lines except those near bus lines, proposing several ways to better its ability with false recognition, at last its pattern recognition quality is analyzed.

Keywords: Kohonen neural network; same-tower double-circuit lines; pattern recognition

(上接第3页) 大值制动的制动能力减弱。此时其制动能力反而不如模值和制动。

对相量差动, 当发生轻微内部故障时。差流较小, 而穿越负荷电流使制动电流较大。故应以灵敏度为重。宜用和/差制动方法。对故障分量差动, 不可能出现两侧电流相位差在 180 附近, 此时应以制动性能为重, 宜取最大值制动方式。

$I_{01} = 0$ 的情况比较复杂, 不太利于同条件下比较。但其基本属性与 $I_{01} = 0$ 时是一致的。上述结论也是基本适用的, 此处暂不做进一步讨论。

4 结束语

本文试图用相量分析方法作为运行特性分析的

共同基础, 对三种常用的制动方式进行了分析比较, 文中表明, 这种方法及其分析结果有参考意义。

参考文献:

- [1] 华中工学院. 电力系统继电保护原理与运行[M]. 水利电力出版社, 1981.

收稿日期: 2001-11-27

作者简介: 陈德树(1930-), 男, 教授, 博士生导师, 从事电力系统继电保护等领域的教学、研究工作; 陈卫(1970-), 男, 博士研究生, 主要研究方向为电力系统继电保护与故障分析; 尹项根(1956-), 男, 教授, 博士生导师, 从事电力系统继电保护等领域的教学、研究工作; 张哲(1962-), 男, 教授, 从事电力系统继电保护等领域的教学、研究工作。

The phasor characteristic analysis of differential protection

CHEN De-shu, CHEN Wei, YIN Xiang-gen, ZHANG Zhe

(Huazhong University of Science and Technology, Wuhan, 430074, China)

Abstract: The characteristic of through current restraint depend on selection of restraint current. The different restraint schemes have distinct characteristic. In order to compare the various schemes using general method under the same condition, the novel operation characteristic analyzing method is proposed. The phasor relationship of currents between two terminals is employed to represent the operation characteristic in this paper.

Keywords: differential protection; restraint characteristic; phasor analysis