

基于组合神经网络的输电线故障类型识别

张兆宁^{1,3}, 毛鹏², 郁惟镛¹, 范春菊¹

(1. 上海交通大学电力学院, 上海 200030; 2. 天津大学电气自动化与能源工程学院, 天津 300072;

3. 中国民航学院空管学院, 天津 300300)

摘要: 准确的输电线路故障类型识别是实现故障测距的前提, 文中在高压输电线路故障分析的基础上, 构建了由 Kohonen 自组织特征映射神经网络模型和 BP 网络模型组合而成的类型识别网络模型, 来实现输电线路的故障检测及故障类型识别。经理论分析和大量的 EMTP 仿真表明: 此网络模型较单一网络模型, 所需训练样本少, 学习时间短, 并且在各种故障模式下, 均能可靠、准确实现输电线路故障类型的识别, 不受故障过渡电阻、故障初始角、系统运行方式、故障点位置等因素的影响。

关键词: 故障类型识别; 神经网络; 输电线

中图分类号: TM773

文献标识码: A

文章编号: 1003-4897(2001)04-0001-05

1 引言

高压输电线路故障发生后, 可靠、准确的故障类型识别对于分析、排除故障具有非常重要的意义。故障类型识别是根据故障发生后可获得的信息来实现 10 种故障类型, 即单相接地故障 (A-G, B-G, C-G)、两相短路故障 (A-B, A-C, B-C)、两相短路接地故障 (A-B-G, A-C-G, B-C-G) 和三相短路故障 (A-B-C 或 A-B-C-G) 的识别, 因此, 完全可以看成是一个模式识别问题。

故障类型识别功能的实现, 大体可以分解为两部分: 一则是输电线路故障发生后, 对应于故障模型的特征向量的提取; 二则是根据故障特征向量实现分类或识别的方法。对于第一点, 就目前文献, 大体有这样几种: 文献^[1,2]采用故障行波的波头, 文献^[3~6]采用故障电压、电流的基频分量, 文献^[7]采用故障电压中的某段高频分量, 文献^[8,9]则直接应用故障后电气量的采样序列值。对于第二点, 大体分为两类: 解析方法, 即首先采用某种模变换方法 (如文献^[9]采用的 Clark 变换、文献^[2]采用的凯伦贝尔变换等) 变换故障电气量, 然后通过设置门槛值、根据某种逻辑关系来实现故障类型识别的方法, 以及神经网络方法^[5,8,10]。

高压输电线路发生故障后, 线路终端的可测信息受系统运行方式、故障点位置、过渡电阻等随机因素的影响, 整个故障模式空间一般来讲是非线性可分的, 所以传统的解析方法必然存在一定的不足, 文献^[6,7]引入了模糊集合理论, 在一定程度上对于线性划分方法的不合理性有一定的改善。对于继电保护元件强调实时性, 而故障测距作为故障后分析元

件, 准确性更为重要, 并且测距元件一般安装于终端监视 PC 机或单独构成装置, 从而为采用复杂方法实现测距各部分功能 (包括类型识别模块) 提供了前提条件。神经网络以其固有的自学习、自组织、强鲁棒性等方面的突出特点在模式识别中具有重要地位, 神经网络通过对样本的学习调整整个权空间, 可以实现任意复杂的逻辑关系表达式, 由此, 在故障类型识别模块中, 采用神经网络方法具有一定的优越性。

故障后根据故障可测信息来准确提取反映于故障模式的特征向量是实现正确识别的前提条件。应用故障行波波头检测来实现模式识别, 原理简单, 但由于故障行波受系统拓扑结构、故障点位置及故障发生时刻等方面的影响, 准确的捕捉、识别所需的行波波头尚有一些技术细节期待解决, 另外, 波头检测意味着高速采样, 现阶段硬件水平还不能完全满足要求, 因此, 基于此方法的故障类型识别元件现场可靠性与准确度并不高。应该说, 线路故障后, 按照一定频率采样的电气量的时序序列 (即故障波形) 在误差允许范围内, 表征着实际的物理信号, 包含有完全的信息, 但对于故障类型识别这一特定目标问题, 无疑其信息含量是冗余的, 且所需信息特征不突出。直接采用采样序列的方法^[8,9], 在某种意义上体现了这种思想。但是, 现场中类型识别所用的采样序列是依次经互感器变换、数字量化 (即 AD 转换)、数字信号读取等一序列环节, 其中必然会存在误差和干扰信息, 并且采用采样序列的方法, 数据窗不可能太长, 否则实现太复杂, 综合两方面, 此类型识别方法可靠性不高, 现场准确性也难以保证。高压输电系统中性点是直接接地的, 不论发生何种类型的故

障,故障形态都比较明显,集中表现在故障后,基频分量变化比较突出,文献^[3]在输电线路故障暂态信号分析中指出:电力系统故障电气量是一个随机过程,故障引起的暂态具有非平稳性,信号功率谱中暂态功率谱与基频功率谱相比是很小的,且当电压过零点时故障暂态分量更小。综上所述,高压输电线路故障类型识别中,采用故障电气量的基频分量形成故障模式的特征分量具有一定的优越性。

本文由输电线路故障电压、电流的基频分量,以及反映于接地故障类型的零序电流来形成类型识别的特征向量,采用组合神经网络来实现故障模式的识别,即先由 Kohonen 自组织特征映射神经网络(SOMNN)来对输入特征向量实现矢量量化、或者说特征的二次提取,然后由具有强大非线性映射功能的BP网络来最终实现故障类型的准确识别。

2 故障类型识别组合神经网络

2.1 组合神经网络模型构建

输电线路故障类型识别中故障特征向量提取时,现有方法中有的基于故障电压、有的基于故障电流,表明电压和电流都在一定程度上表征着其所对应的故障模式。自组织特征映射神经网络(SOFM)可以实现输入向量的特征映射,实现矢量量化(Vector quantization)及特征的进一步提取。因此,可以降低对特征向量构建的要求,由故障电压、电流直接形成具有冗余信息的输入向量,通过SOFM来实现特征映射。

自组织神经网络是神经网络研究人员在人脑功能分区结构,以及后天对周围环境自适应学习、记忆等信息处理机制的启发研究下的产物,具有较强的生物背景。自组织神经网络的基本结构由输入层和输出层(竞争层)组成,输入层神经元个数由输入向量的维数决定,输出层为二维阵列,其具体数目与实现特征映射问题的复杂度,即输入向量在某种规则下的相似度以及输出目标函数来决定,至今并未有实际可行的数学算法来计算,只能通过反复实验的方法来近似的找到最佳个数。

SOFM网络根据学习规则,能够实现输入模式的自动分类,即在无监督情况下,通过对输入模式的自组织学习,在输出层将分类结果表示出来,但自组织特征映射网络具有别于其他类型网络的特点:SOFM不是以一个神经元或者网络的状态矢量反映识别(分类)结果,而是以若干神经元同时(并行)反映分类结果,即其中任何一个神经元都能代表分类

结果或近似分类结果。也就是说,SOFM通过学习,形成了输入模式空间的聚簇,因此直接应用其来实现输电线路故障模式识别是不恰当的。发展比较成熟、且在许多领域有成功应用先例的BP网络模型,理论上可以拟合任何非线性函数,实现复杂的逻辑判断。因此,我们提出在SOFM输出层上增加一具有单隐层的BP网络模型,即组合神经网络模型,来实现输电线路故障类型的可靠、准确识别。组合神经网络的模型结构示意图如图1示。

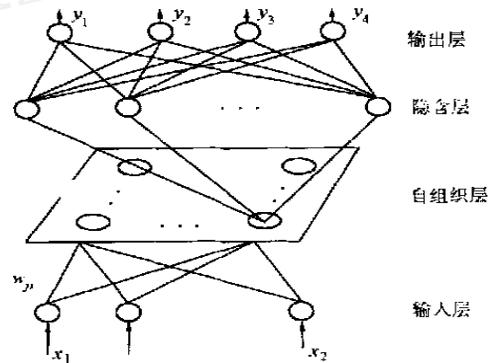


图1 输电线路故障类型识别网络模型

图1所示输电线路故障类型识别网络模型中层与层之间节点全连接,输入层与自组织层之间的权值调整通过无导师训练自学习完成,自组织与隐含层以及隐含层与输出层之间的权值调整采用BP算法来实现。输出层包含4个神经元,通过其输出的编码来表示输电线路的各种故障类型和正常状态,详见表1。

表1 故障类型输出编码表

故障类型	A	B	C	G	故障类型	A	B	C	G
	y_1	y_2	y_3	y_4		y_1	y_2	y_3	y_4
A相接地	1	0	0	1	AC相短路	1	0	1	0
B相接地	0	1	0	1	AB相短路接地	1	1	0	1
C相接地	0	0	1	1	BC相短路接地	0	1	1	1
AB相短路	1	1	0	0	AC相短路接地	1	0	1	1
BC相短路	0	1	1	0	三相短路	1	1	1	0
					正常	0	0	0	0

2.2 组合神经网络训练算法

输电线路故障类型识别网络的学习分三步进行,首先是自组织层无导师学习阶段,然后根据自组织层对输入故障模式空间的特征映射及目标输出形成BP网络的学习样本,最后通过导师指导训练BP网络的权空间。自组织层的学习规则按照如下步骤

进行:

(1) 初始化。将输入层与自组织层之间的权向量 $\{W_{ij}\}$ 赋予 $[0, 1]$ 区间的随机值, 确定学习速率初始值 $\alpha(0) = 0.8$, 确定领域的初始值 $N_g(0) = M$ (即等于整个自组织层);

(2) 输入一样本, 计算自组织层 j 节点连接权矢量 $\vec{W}_j = [w_{j1}, w_{j2}, \dots, w_{jN}]^T$ 与输入向量 $\vec{X}_p = [x_1^p, x_2^p, \dots, x_N^p]$ (其中 p 为样本编号) 之间的欧氏距离:

$$d_j = \sqrt{\sum_{i=1}^N (x_i^p - w_{ji})^2} \quad (j = 1, 2, \dots, M) \quad (1)$$

(3) 找出最小距离 $d_g = \min [d_j] (j = 1, 2, \dots, M)$, 确定获胜神经元 g 。

(4) 调整权空间。对自组织层第 g 神经元的领域 $N_g(t)$ 内所有的神经元与输入层神经元之间的连接权进行修正:

$$w_{ji}(t+1) = \begin{cases} w_{ji}(t) + \alpha(t) [x_i^k - w_{ji}(t)] & j \in N_g(t) \\ w_{ji}(t) & j \notin N_g(t) \end{cases} \quad (2)$$

$$(i = 1, 2, \dots, N)$$

其中 t 为权值调整次数。

(5) 对连接权矢量 $\vec{W}_j(t+1)$ 进行归一化处理:

$$\vec{W}_j(t+1) = \frac{\vec{W}_j(t+1)}{\sqrt{w_{j1}(t+1)^2 + w_{j2}(t+1)^2 + \dots + w_{jN}(t+1)^2}} \quad (3)$$

(6) 将下一个学习样本输入网络输入层, 返回步骤 2, 直至所有的样本全部提供一遍。

(7) 更新学习速率 $\alpha(t)$ 和领域 $N_g(t)$:

$$\alpha(t) = \alpha_0 \left(1 - \frac{t}{T}\right);$$

$$N_g(t) = \text{INT} [N_g(0) \left(1 - \frac{t}{T}\right)] \quad (4)$$

其中, T 为学习总次数, $\text{INT}[x]$ 表示对 x 取整运算。

(8) 令 $t = t + 1$, 返回步骤 2, 直至 $t = T$ 。

在权矢量调整中, 对其作了归一化处理, 从而只保留了矢量中的方向因素, 使权矢量以较快速度调整的与对应的输入向量方向趋于一致, 能有效地缩短网络学习时间。无导师自组织学习完毕, 固定权空间, 依次输入学习的样本 (即输电线路故障模式), 并记录自组织层各神经元的输出。自组织层神经元的输出向量与其所对应故障模式的最终理想输出 (参见编码表 1) 形成 BP 网络模型的训练样本。在

导师监督下, 训练 BP 网络, 直至达到目标误差。这样, 应用于输电线路故障类型识别的组合神经网络模型学习完毕, 即可应用。

3 故障类型识别网络的仿真测试

3.1 学习故障模式的形成

神经网络的学习过程, 是网络权值空间形成特征映射, 实现模式识别的过程。所以, 神经网络的学习训练故障模式应尽可能覆盖整个故障模式空间。网络学习样本集的原始故障数据采用 EMTP 仿真程序获得。所采用的系统模型及参数如图 2 所示。输电线路均采用分布式参数模型。

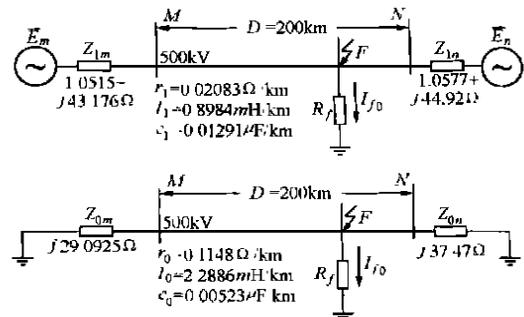


图 2 仿真系统结构及参数

生成类型识别神经网络的学习故障模式, 考虑以下方面:

- 输电线路 10 种故障类型以及非故障状态;
- 故障过渡电阻 $R_g (0, 10, 50, 150, 300)$, 对于两相短路接地故障其相间过渡电阻为 5 ;
- 故障点位置 (线路长度的 50%);
- 故障初始角 $(0, 30, 60, 90)$ 度, 以 A 相电压为基准;

- 负荷 $(0, 50, 100\%)$ 额定负荷;

经上述因素组合产生 $11 * 1 * 5 * 4 * 3 = 660$ 种故障模式。

3.2 调整向量的形成

考虑到高压输电线路发生故障后, 由于线路保护元件的动作, 不可能获得稳态故障电流, 因此提取基频分量必然存在一定的误差, 采用神经网络方法以及对输入向量的预处理, 完全可以避免此因素的影响, 另外采用神经网络来实现故障类型识别并未建立在精确的基频分量的量化关系上, 而在于对输入向量方向的识别。我们就故障发生后第三周的采样, 应用全周差分傅氏算法提取三相电压、三相电流以及零序电流的基频分量, 各相量均采用极坐标形式表示。

不同故障条件,直接计算的电气量具有很大的离散性,为强调故障特征向量元素之间的相互关系,淡化单独元素的绝对值,对输入向量采用如下的归一化:

(1) 归一化三相电压幅值:

$$\bar{U}_p = [U_a^p, U_b^p, U_c^p] = \frac{\bar{U}_p}{U_p}$$

$$\bar{U}_p = [(U_a^p)^2 + (U_b^p)^2 + (U_c^p)^2]^{1/2} \quad (5)$$

其中 \bar{U}_p 为第 p 个样本故障模式直接提取的电压幅值向量。

(2) 归一化三相电流幅值:

$$\bar{I}_p = [I_a^p, I_b^p, I_c^p, I_0^p] = \frac{\bar{I}_p}{I_p}$$

$$\bar{I}_p = [(I_a^p)^2 + (I_b^p)^2 + (I_c^p)^2 + (I_0^p)^2]^{1/2} \quad (6)$$

其中 \bar{I}_p 为第 p 个样本故障模式直接提取的电流幅值向量。

(3) 归一化电气相量的初相角。首先将直接计算的各相量初相角转化为相对相角,我们不妨以 A 相电压初相角为参考基准,计算其他相量的相对相角,然后将所有的相对相角调整到 $[-\pi, +\pi]$ 之间,形成相对相角向量 $\bar{\varphi}_p = [\varphi_s]$, 其中 $s = \{U_b, U_c, I_a, I_b, I_c, I_0\}$, 最后按照公式(7)归一化。

$$\bar{\varphi}_p = \frac{\varphi_s}{\pi} \quad (7)$$

(4) 形成网络输入向量 $\bar{X}_p = [\bar{U}_p, \bar{I}_p, \bar{\varphi}_p]$, 其为 13 维向量,由此决定了识别神经网络的输入层包含后 13 个神经元。

3.3 测试结果

为综合评价此识别系统的整体性能,形成故障类型识别神经网络的测试故障模式集:

- 故障过渡电阻 $R_g(5, 30, 200 \Omega)$, 对于两相短路接地故障其相间过渡电阻为 10Ω ;
- 故障点位置(线路长度的 20%、80%);
- 故障初始角(15、45、75 度,以 A 相电压为基准);
- 负荷(10%、80%额定负荷);

经组合形成 $11 * 3 * 2 * 3 * 2 = 264$ 个测试故障模式,由 EMTP 产生故障原始数据,按照相同于学习样本的构建方法,形成测试样本集。对于测试样本集,输电线路故障类型识别神经网络的识别准确率达到了 100%。由此可知,由自组织神经网络和 BP 网

络模型组合而成识别网络模型完全可以胜任故障测距元件的故障分类功能。

4 结论

在高压输电线路故障特征分析的基础上,参考现有文献提出的故障类型识别方法,以模式识别的观点采用神经网络方法来实现了故障类型的分类。本文提出了一种新型的网络模型结构,即采用自组织特征映射神经网络和 BP 神经网络的组合神经网络模型,此模型充分发挥了自组织神经网络在输入矢量化、特征提取以及 BP 网络在非线性函数拟合等方面的突出优点,实现了输电线路故障类型的可靠、准确识别,为故障测距提供了重要前提,理论及仿真表明此识别网络模型具有以下特点:

降低了对输入特征向量提取的要求。自组织学习层的存在,不再强调精确提取反映故障模式的故障特征向量,由故障电压和电流的基频分量构成信息冗余输入向量,由自组织学习层实现特征聚簇,即特征二次提取。

所需学习样本少。采用组合神经网络模型比采用单一的 BP 网络模型结构训练时所需的故障模式少,由于输入向量的归一化处理以及自组织特征映射的矢量化,突出了输入向量的方向,所以训练时,没有必要沿线路全程获取学习故障模式,仅采用线路一点(仿真时为 50%)就完全可以满足要求。

对于新的输入特征向量,不需要整个权空间的重新调整,从而降低了运行、维护工作量。

基于 MATLAB 语言,对提出的故障识别模型进行了训练和测试,各项性能指标均满足要求,通过此问题的解决,我们不难得到这样的启发:对于发展相对成熟的神经网络技术,如何实现更加复杂的目标功能,采用各种网络模型的有机组合不失为一条有效的研究途径,合理的组合将起到对各单一神经网络模型扬长避短的效果,会大大地开拓神经网络技术的应用领域。

参考文献:

- [1] 董新洲,贺家李,葛耀中.基于小波变换的行波故障选相研究(第 1 部分:理论基础).电力系统自动化,1998,22(12):24-26.
- [2] 董新洲,贺家李,葛耀中.基于小波变换的行波故障选相研究(第 2 部分:仿真实验结果).电力系统自动化,1999,23(1):20-22.
- [3] 王晓茹,伍思淘,钱清泉.一种基于神经网络的高压输电线路故障分类器.电力系统自动化,1998,22(11):28-

- 31.
- [4] 徐振宇,杨奇逊,刘万顺,张振华.一种序分量高压线路保护选相元件.中国电机工程学报,1997,17(3):214-216.
- [5] Badrul H Chowdhury, Kunyu Wang. Fault Classification Using Kohonen Feature Mapping. Proc Of 1996 Inter Conference On Intelligent System Applications to Power Systems (ISAP '96), Orlando, USA, 1996:194~198.
- [6] Alessandro Ferrero, Silvia Sangiovanni, Ennio Zappitelli. A Fuzzy Set Approach to Fault Type Identification in Digital Relaying. IEEE Transactions on Power Delivery, 1995, 10(1):169-175.
- [7] 焦邵华,刘万顺,肖仕武.基于故障产生的电压暂态高频分量的模糊选相新原理.电力系统自动化,1999,23(9):15-18.
- [8] Aggarwal R K, Xuan Q Y, Dunn R W. A Novel Fault Classification Technique for Double-circuit Lines Based on A Combined Unsupervised/ Supervised Neural Network. IEEE Transactions on Power Delivery, 1999, 14(4):1250-1255.
- [9] 王安定,葛耀中.一种新型数字式故障选相方案.中国电机工程学报,1990,10(3):67~72.
- [10] Thomas Dalstein, Bernd Kulicke. Neural Network Approach To Fault Classification For High Speed Protective Relaying. IEEE Transactions on Power Delivery, 1995, 10(2):1002-1010.

收稿日期: 2000-09-28

基金项目: 中国民航总局教育基金资助项目(98-3-04)

作者简介: 张兆宁(1964-),男,博士,副教授,主要从事电力系统故障信号分析,小波分析及其应用研究工作; 毛鹏(1973-),男,博士,主要从事电力系统智能型故障测距,变电站综合自动化研究工作; 郁惟镛(1940-),男,教授,主要从事电力系统继电保护及综合自动化研究与教学工作。

The discrimination of the fault type of the transmission line based on combined neural network

ZHANG Zhao-ning^{1,3}, MAO Peng², YU Wei-yong¹, FAN Chun-ju¹

(1. Shanghai Jiaotong University, Shanghai 200030, China; 2. Tianjin University, Tianjin 300072, China;

3. Civil Aviation University of China, Tianjin 300300, China)

Abstract: Accurate discrimination of the fault type of the transmission line is a key to the fault location. Based on the fault analysis of the high voltage transmission line, the type discriminated network model is created that combines Kohonen self-organized feature mapping network and the BP network in order to implement the detection and discrimination of the fault type of the transmission. The theory analysis and the EMTP simulation indicate that this combined network needs less training stylebook and is learnt quicker than the single network. The combined network can achieve the discrimination of the fault type of the transmission line reliably and accurately under any kind of the fault mode, not influenced by the transition resistance, the starting angle of the fault, operation of the power system and the location of fault.

Keywords: discrimination of the fault type; neural network; transmission line