

小电流系统单相接地选线的两种新思路

刘宇 申东日 抚顺石油学院自动化系 (113001)

【摘要】 针对小电流系统单相接地的实际情况,将 Bayes 决策和多层前馈神经网络分别用于故障线路的选择,仿真实验结果令人满意。

【关键词】 Bayes 决策 神经网络 小电流系统 单相接地

引言

我国 6~35kV 电力系统大部分采用小电流接地运行方式。在小电流接地系统中,发生单相接地不形成短路回路,规程规定可继续运行 1~2 小时^[1]。在此期间,应迅速查找到故障线路将其切除,否则,会造成故障扩大,如引发相间短路,母线烧毁等,威胁电力系统及设备的安全。

在单相接地选线方面的研究已有多年的研究,选线方案发展到群体比幅比相^[2-4]。其基本原理是:故障线路零序电流幅值最大且与非故障线路零序电流方向相反。但是,由于噪声、干扰等的影响,所采集到的零序电流无论幅值还是相角有可能均不满足上述关系,不可避免出现误判、漏判。文^[4]根据群体比幅比相将五种方案综合考虑,按模糊决策组合裁决;文^[5]考虑了电流互感器二次侧的不平衡电流,进一步提高了选线精度。

如果将故障后各线路零序电流组成该类故障的一个模式,选线的目的就是判断这个故障模式的所属类别,这是一个典型的模式识别问题。作者从这方面入手,研究了小电流系统发生单相接地故障时的线路选择问题。

统计模式识别的一个基本方法是贝叶斯(Bayes)决策^[6]。本文首先采用基于最小错误率的 Bayes 决策方法,来对故障线路进行识别。

近年来,人工神经网络的研究取得很大进展,神经网络的自学习、自组织、自适应及容错

性,使它在模式识别、系统辨识、自动控制、信号处理、故障诊断等诸多领域获得了成功应用^[7]。并且,人们普遍认为,模式识别是神经网络应用最成功的领域。如果用已知的故障模式训练神经网络,构成一个神经网络模式分类器,便可对未知属性的故障模式分类判别。基于这个思想,我们随后将多层前馈神经网络用于单相接地故障选线,仿真结果令人满意。

最后,简要探讨了两种方法的关系。

1 Bayes 决策理论

在我们的实际问题中,希望误判的几率最小,即希望尽量减少分类的错误,从这样的要求出发,可以采用统计模式识别中基于最小错误率的贝叶斯决策方法。

若已知一批样本的集合 $X = \{x_1, x_2, \dots, x_N\}$ 共有 c 类,其中每个 x_i 是 n 维向量。并且已知在 X 中有 N_1 个点属于 C_1, N_2 个点属于 C_2, \dots, N_c 个点属于 C_c ,存在一未知类别的向量 x 。设 $p(i)$ 为 C_i 的先验概率; $p(x|C_i)$ 为 C_i 类中出现 x 的概率,即类条件概率密度; $p(C_i|x)$ 为后验概率,即 $x \in C_i$ 的概率。

$$\ln g_i(x) = \ln p(x|C_i) + \ln p(C_i) \quad (1)$$

则贝叶斯判决准则为

$$\text{若 } g_i(x) > g_j(x), j = i, j = 1, \dots, c \quad (2)$$

则 $x \in C_i$

在电缆线路单相接地故障中,我们以各线路零序电流为故障模式特征,理论上,各线路零序电流只与线路结构、电压等级有关。故每一类故障发生时,其故障模式应当是固定的。但是由于噪声、测量误差、干扰等的影响,实际每

一类故障模式都是一个多维随机变量,可以认为它是服从正态分布的。则故障模式 x 的分布密度此时可表示为

$$p(x|u_i) = N(u_i, \Sigma_i) = \frac{1}{(2\pi)^{\frac{n}{2}} |\Sigma_i|^{\frac{1}{2}}} \exp \left[-\frac{1}{2} (x - u_i)^T \Sigma_i^{-1} (x - u_i) \right] \quad (3)$$

其中 u_i 是 i 类模式的 n 维均值矢量, Σ_i 是 i 类模式的 $n \times n$ 维协方差矩阵。 $|\Sigma_i|$ 是 Σ_i 的行列式。

将(3)代入(1)式得:

$$g_i(x) = -\frac{1}{2} (x - u_i)^T \Sigma_i^{-1} (x - u_i) - \frac{1}{2} \ln |\Sigma_i| + \ln p(i) - \frac{n}{2} \ln 2 \quad (4)$$

利用最大似然估计得正态分布的参数估计为

$$\hat{u}_i = \frac{1}{N_{i,k=1}^{N_i}} \sum_{k=1}^{N_i} x_k \quad (5)$$

$$\hat{\Sigma}_i = \frac{1}{N_{i,k=1}^{N_i}} \sum_{k=1}^{N_i} (x_k - \hat{u}_i)(x_k - \hat{u}_i)^T \quad (6)$$

式中 x_k 为 i 的第 k 个样本, \hat{u}_i 是均值矢量 u_i 的最大似然估计, $\hat{\Sigma}_i$ 是协方差矩阵 Σ_i 的最大似然估计。此时,就可以代入(4)式,然后根据式(1)的贝叶斯准则对未知故障模式进行分类判断了。

2 多层前馈神经网络简介

多层前馈神经网络由不同层的节点集合组成^[7],每一层的节点输出到下一层的节点,除输入层外,每一节点的输入均为前一层所有节点输出值的加权和;每一节点的激励输出 o_j 由节点输入 o_i , 激励函数 f 及节点阈值 θ_j 共同决定。设 w_{ij} 第 i 个节点到下一层第 j 个节点的联接权值,则 $o_j = f(\sum_i w_{ij} o_i - \theta_j)$, 通常激励函数 f 取 Sigmoid 函数,即 $f(u) = \frac{1}{1 + e^{-u}}$ 。

设 y_l^p 为第 p 个输入样本在网络第 l 个输出节点的实际输出, t_l^p 为相应的期望输出。网络总的均方误差定义为

$$E = \sum_p \sum_l (t_l^p - y_l^p)^2 \quad (7)$$

对给定的学习样本,学习的目的就是调整各节点之间的权值和各个节点的阈值,使网络的实际输出与期望输出之间的均方误差最小,利用梯度下降法,可得到权值和阈值的调整规则如下:

对第 p 个输入样本

$$j_i(n) = w_{ji} j_i + \theta_{ji} (n-1) \quad (8)$$

式中 $j_i(n) = w_{ji} j_i(n) - \theta_{ji} (n-1)$, j 可表示输出层或隐层, n 为迭代次数, η 为学习步长, α 为惯性因子。

对于输出层节点 k :

$$t_k = (t_k - y_k) y_k (1 - y_k) \quad (9)$$

对于隐层节点 j :

$$j = j(1 - j) \sum_k t_k w_{kj} \quad (10)$$

神经网络的拓扑结构根据具体问题选取。学习步长,惯性因子及隐层单元个数则在实验中凭经验确定,以得到较佳的收敛速度。训练之前,一般初始权值赋以 $[-0.5, 0.5]$ 之间的随机数。

神经网络的如下特点对我们构造神经网络分类器是极为有利的:

(1) 分布式存储具有很强的容错性。神经网络分类器一般对输入模式信息的不完备或特征的缺损不太敏感,和传统的模式识别方法比较起来,神经网络分类器在背景噪声统计特性未知的情况下,其性能更好,而且神经网络具有更好的推广能力。

(2) 具有很强的自学习或训练功能:网络根据接受周围环境的信息不断调整自己,适应环境的变化。

3 样本的准备

设 10kV 电力系统一段母线上共有 n 条出线,每条线路长度、导线型号均已知。考虑单相金属性接地情况,则可计算出各线路额定电压下的电容电流,具体计算如下^[8]:

$$I_{ck} = \frac{95 + 2.84S}{2200 + 6S} U_e I_k \quad (k = 1, \dots, n) \quad (11)$$

式中 S —— 电缆芯线截面, mm^2

U_e —— 额定电压, 10kV

若线路 j 发生单相接地, 则线路 j 的零序电流 I_{0j} 为

$$I_{0j} = \sum_{k=1}^n I_{ck} \quad (12)$$

而非故障线路零序电流

$$I_{0k} = I_{ck}, (k \neq j, k = 1, \dots, n) \quad (13)$$

但是, 仅仅由零序电流的幅值不足以反映系统的全部故障特性。零序电压和各线路零序电流之间的相位差 φ_k 也是系统的故障特征。在理论上,

$$\varphi_k = \begin{cases} 90^\circ, & k = j \\ -90^\circ, & k \neq j \end{cases} \quad (14)$$

而实际测得的相位差并不精确等于 90° 或 -90° , φ_k 变化范围为 $[-180^\circ, 180^\circ]$ 。综合考虑零序电流的幅值特性和相位特性, 我们用一个量 $I_k = I_{0k} \text{sig}(\varphi_k)$ (*) 来表示系统某一故障模式的第 k 个分量, $\text{sig}(\cdot)$ 为符号函数。则整个模式可用一个相量 x 表示, 即 $x = \{I_1, I_2, \dots, I_n\}$ 。

对 n 条线路, 考虑母线接地, 共有 $n+1$ 类故障, 第 i 类有 N_i 个模式样本, 用 $x_j^{(i)}$ 表示第

i 类故障中的第 j 个模式样本, $j = 1, \dots, N_i$ 。则

$$x_j^{(i)} = \{I_{j1}^{(i)}, I_{j2}^{(i)}, \dots, I_{jk}^{(i)}, \dots, I_{jn}^{(i)}\}, i = 1, \dots, c, k = 1, \dots, n \quad (15)$$

其中 $x_j^{(i)}$ 中的每个分量 $I_{jk}^{(i)}$ 均可由 (*) 式求出。

4 仿真实验及结果分析

仿真实验中, 以一段 10kV 母线下 5 条出线为例。按上面所述, 可得单相金属性接地情况下 6 个标准样本。将每个样本分别加 10% 的均匀分布随机噪声 5 次, 和原样本一起共得 36 个样本。其中 30 个为训练样本, 其余 6 个为测试样本。

根据训练样本, 求得每一类的均值矢量和协方差矩阵, 构成 Bayes 分类器。训练神经网络时, 输出教师信号如下安排: 若样本属于第 i 类, 则网络第 i 个输出单元为 1, 其余单元输出为 0; 若为母线接地, 则第 $n+1$ 个输出单元为 1, 其余单元输出为 0。实际上, 为便于网络收敛, 以 0.9 代替 1, 以 0.1 代替 0。当网络输出达到所需的精度, 训练结束。

表 1 Bayes 分类器测试结果

	输入样本					分类输出						样本类别	分类结果
	I_1	I_2	I_3	I_4	I_5	g_1	g_2	g_3	g_4	g_5	g_6		
1	-4.946	1.056	0.913	1.288	3.470	2.418	-167.8	-243.2	-4171	-853.3	-325.6	1	1
2	0.176	-2.713	2.817	-0.164	1.312	-143.5	-1.601	-7795	-2175	-358.4	-215.6	2	2
3	0.210	2.771	-2.361	2.862	2.590	-351.3	-1258	-4.595	-168.4	-434.7	-794.5	3	3
4	-1.196	0.833	1.045	-2.818	1.372	-189.4	-313.5	-589.4	-7.715	-251.2	-1167	4	4
5	-1.318	0.959	0.263	0.458	-4.574	-257.8	-447.3	-382.1	-89.44	0.338	-1647	5	5
6	0.629	2.636	1.463	-0.871	1.678	-98.62	-258.4	-2167	-182.6	-224.3	-12.29	6	6

表 2 神经网络分类器测试结果

	输入样本					分类输出						样本类别	分类结果
	I_1	I_2	I_3	I_4	I_5	o_1	o_2	o_3	o_4	o_5	o_6		
1	-4.946	1.056	0.913	1.288	3.470	0.856	0.012	0.113	0.053	0.179	0.086	1	1
2	0.176	-2.713	2.817	-0.164	1.312	0.027	0.897	0.016	0.121	0.056	0.102	2	2
3	0.210	2.771	-2.361	2.862	2.590	0.110	0.037	0.905	0.107	0.045	0.165	3	3
4	-1.196	0.833	1.045	-2.818	1.372	0.034	0.221	0.132	0.887	0.052	0.102	4	4
5	-1.318	0.959	0.263	0.458	-4.574	0.135	0.021	0.106	0.119	0.879	0.092	5	5
6	0.629	2.636	1.463	-0.871	1.678	0.074	0.162	0.191	0.075	0.205	0.828	6	6

经检验, 上述两种分类器对训练样本均能正确识别, 限于篇幅, 不予列出。下表给出对测

试样本的分类结果。

可以看出, 对测试样本 3、4、5, 按群体比幅

比相原理无疑会误判,但是, Bayes 分类器和神经网络分类器均判断正确。一般而言,模式是一种特征的数据结构,它包含特征名称、特征值以及特征间关系的或明或暗的信息,模式识别的本质是对一个信息事件的并行处理,信息的所有项同时作用,产生决策。因此,具有并行分布处理的系统是更适于模式识别的。群体比幅比相实际上也是一个模式识别过程,但它是将模式的某个分量与其它分量逐个相比较,根据预定的规则(如幅值最大或相位相反)作出判断,它本质上是串行的,因而分类较为机械,不具容错性。而 Bayes 分类器和神经网络分类器正体现了对模式处理的并行性,且具容错性,所以较群体比幅比相有更好的分类效果。

文^[9]证明了多层前馈网络用做分类器时,其输出函数在最小方差意义下能以任意精度逼近 Bayes 决策函数,所以,当训练样本取得足够大时,两种分类器的效果是一样的。

另外,由于我们的分类器具有学习能力,系统发生故障后,把所得的故障模式加入训练样本中重新训练,将使分类器的识别精度即选线精度不断提高。

5 结论

本文分别用 Bayes 决策和多层前馈网络实

现了小电流系统发生单相接地时的故障线路选择。由于它们本质上是对信息的并行处理,具有自适应性和容错性,比传统的选线方法更为有效。相信,按照上述方法生产的选线装置,来判断接地线路,会有更高的精度。

参考文献

- 1 郝玉山等. 小电流接地系统单相接地保护原理和技术综述. 电力情报, 1994(2).
- 2 IEEE guide for the application of neutral grounding in electrical utility systems. Part IV - distribution, Surge - Protective Devices Committee of the IEEE Power Engineering Society. USA, 1992
- 3 Bnkktoyarov V. E. polyakov V. E. Current protection against single - phase ground short circuits in networks with un - ground neutral. Electric and electronic Abstracts, 1989. 2
- 4 郝玉山等. 小电流接地微机选线的群体比幅比相原理. 电力情报, 1994(2)
- 5 檀国彪等. 基于最大 I_{sin} 或 (I_{sin}) 原理的微机选线装置. 中国电力. 1995(7)
- 6 边肇棋等著. 模式识别. 清华大学出版社, 1988
- 7 杨行峻、郑君里. 人工神经网络. 高等教育出版社, 1992
- 8 航空工业部第四规划设计院等编. 工厂配电设计手册. 水利电力出版社, 1983
- 3 翟东晖、张立明. 多层前馈网络在模式识别中的理论和应用. 电子学报, 1995, 23(7)

TWO NEW METHODS FOR DISCIMINATION THE DEFAULTED LINE OR BUS IN THE POWER SYSTEM WITH FLOATING NEUTRAL

Liu Yu, Shen Dongri (Department of Automation, Fushun Petroleum Institute, Fushun, 113001)

Abstract Based on the reality of the power system with floating neutral, We apply Bayes decision and multi-layered feed-forward neural network to discriminate the defaulted line or bus. The simulation results illustrate the effectiveness of the two methods.

Key words Bayes decision Neural network Power system with floating neutral Singlephase to ground