

基于模糊神经网络的故障测距

刘凤霞^{1,2}, 刘前进¹

(1. 华南理工大学 电力学院, 广东 广州 510640; 2. 揭阳供电局, 广东 揭阳 522000)

摘要: 输电线路故障受到许多不确定性因素影响, 传统测距算法不能很好地解决输电线路测距问题。提出了基于模糊神经网络(FNN)的故障测距方法, 构造了一个由输入层、模糊化层、推理层、去模糊化层、输出层组成的模糊神经网络, 采用变步长方法改进 BP 算法, 加快了收敛速度。仿真结果显示, 设计的网络具有良好的适应性能, 其测距精度较高, 且测距精度不受系统运行方式、过渡电阻、两端系统相角差等的影响。

关键词: 输电线路; 故障测距; 模糊神经网络; 分层分布

中图分类号: TM 711

文献标识码: A

文章编号: 1006-6047(2006)05-0032-03

本文尝试利用模糊神经网络(FNN)强大的非线性逼近能力, 根据故障后继电器保护安装处测得故障后第一周期的三相电压、电流以及判断接地故障的零序电流基频分量作为模糊神经网络的输入, 构造一个由输入层、模糊化层、推理层、去模糊化层、输出层组成的模糊神经网络实现准确的故障测距。

1 故障测距总结构设计

高压输电线路的故障测距是一个复杂多方面信息处理系统, 它包含故障检测、故障鉴别和故障定位。若采用单一的 FNN, 输出二维矢量, 分别反映故障距离和故障类型, 这种模型结构隐含层结点数过大, 学习效率极低, 收敛性能差。因此, 采用如图 1 所示的结构——基于分层分布式的 FNN 模型结构^[1-4]。

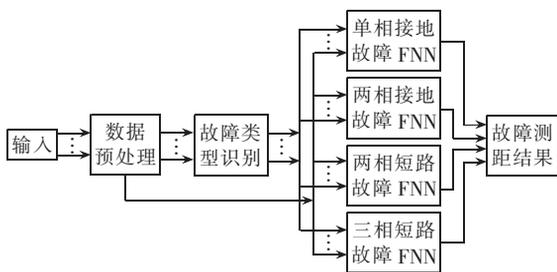


图 1 分层分布式故障测距的总体结构

Fig.1 The overall structure of layered distributed fault locating

用分层分布式模糊神经网络首先识别故障类型, 将故障后所测的三相电压、电流、零序电流幅值及其对应相角等数据经预处理后形成输入向量, 输出为 4 维向量, 用二进制编码分别表示 4 类故障(单相接地、两相短路、两相短路接地和三相短路)的 10 种模式(AG, BG, CG; AB, AC, BC; ABG, ACG, BCG; ABC 或 ABCG)。

下一层为并行分布式故障测距 FNN 模型, 由 4

个相互独立的子测距 FNN 模型组成, 分别完成单相接地、两相短路、两相短路接地和三相短路故障情况下的测距功能。根据上层故障类型识别网络输出故障编码判断故障类型, 选择对应的子测距网络。这些子网络的输入向量是由各自反映故障特征的电气量经预处理后得到的值组成, 输出值为反映故障距离的量。

2 模糊神经网络的建立

模糊神经网络有多种, 人们采用较多的是简化的 T-S 模糊神经网络, 其特点是^[5-8]: 在系统的模糊规则中, “If”部分是模糊的, 而后件“Then”部分是确定的, 为各输入变量的线性组合或常量。这里每条模糊规则的结论都是采用常值形式, 其简化的一种形式为

$$R_j: \text{If } x_1 \text{ is } A_{j1} \text{ and } x_2 \text{ is } A_{j2} \text{ and } \dots x_N \text{ is } A_{jN} \quad (1)$$

$$\text{Then } y_1 = \omega_{j1} \text{ and } y_2 = \omega_{j2} \text{ and } \dots y_M = \omega_{jM}$$

其中 x 和 y 是输入、输出变量; ω_{jk} 是常值, 表示系统第 j 条规则的 k 个输出; A_{ji} 为论域 U_i 上的模糊集合。

模糊神经网络的结构示意图如图 2 所示。

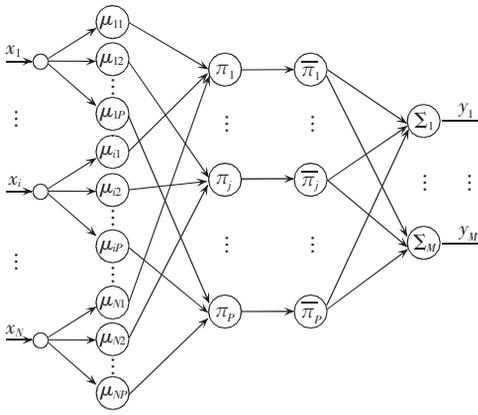
第 1 层为输入层, 该层有 N 个神经元, 输入向量 $x = [x_1, x_2, \dots, x_N]^T$ 传送到下一层。

第 2 层为模糊化层, 设每个输入变量均有 P 个模糊集合, 则该层共有 $N \times P$ 个神经元, 隶属函数选择为高斯函数, 输出为

$$\mu_{ij} = \exp\left(-\frac{(x_i - m_{ij})^2}{\sigma_{ij}^2}\right) \quad (2)$$

其中 $i = 1, 2, \dots, N; j = 1, 2, \dots, P$, 分别表示输入量的维数和模糊集合数。 m_{ij} 和 σ_{ij} 分别表示高斯隶属函数的中心和宽度。

第 3 层为推理层, 该层的神经元个数为 P , 每个神经元代表 1 条模糊规则, 采用 Sum-Product 模糊推理规则, 即



输入层 模糊化层 推理层 解模糊层 输出层

图 2 模糊神经网络模型

Fig.2 The model of fuzzy neural network

$$\pi_j = \prod_{i=1}^N \mu_{ij}(x_i) \quad (3)$$

其中 \$j=1, 2, \dots, P\$ 表示规则数。

第 4 层为解模糊层,该层的作用是实现归一化计算,避免在学习过程中由于各修正量过大而产生振荡。该层的输出可表示为

$$\bar{\pi}_j = \pi_j / \sum_{j=1}^P \pi_j \quad (4)$$

第 5 层为输出层,该层采用加权线性求和法,求出清晰的输出值,即

$$y_k = \sum_{j=1}^P \omega_{jk} \bar{\pi}_j \quad (5)$$

其中 \$\omega_{jk}\$ 表示解模糊层与输出层之间的连接权值, \$k=1, 2, \dots, M\$。

由以上 5 层神经元组成的模糊神经网络具有很强的学习能力。

3 模糊神经网络的学习算法

在模糊神经网络中,学习的方法有很多种,因为 BP 算法是一种运算简单、计算效率高的方法,因此采用 BP 算法,按照反方向误差修正 \$w_{jk}, \sigma_{ij}, m_{ij}\$, 从而完成隶属函数的和规则的自我学习和完善。

网络的误差函数 \$E\$ 为

$$E = \sum_{i=1}^T E_p, \quad E_p = \frac{1}{2} \sum_{k=1}^M (Y_k - y_k)^2 \quad (6)$$

其中 \$y\$ 为实际输出, \$Y\$ 为理想输出, \$T\$ 为训练样本个数。

输出层权值加权的调节公式为

$$\omega_{jk}(n+1) = \omega_{jk}(n) + \eta \Delta \omega_{jk} + \alpha [\omega_{jk}(n) - \omega_{jk}(n-1)] \quad (7)$$

$$\Delta \omega_{jk} = \pi_j (Y_k - y_k) / \sum_k \pi_j \quad (8)$$

其中 \$n\$ 是迭代次数, \$\eta\$ 是学习速率, \$\alpha\$ 是冲量系数。模糊化层的加权调节公式为

$$m_{ij}(n+1) = m_{ij}(n) + \eta \Delta m_{ij} + \alpha [m_{ij}(n) - m_{ij}(n-1)] \quad (9)$$

$$\sigma_{ij}(n+1) = \sigma_{ij}(n) + \eta \Delta \sigma_{ij} + \alpha [\sigma_{ij}(n) - \sigma_{ij}(n-1)] \quad (10)$$

$$\Delta m_{ij} = -\frac{\partial E_p}{\partial m_{ij}} = \delta_j^2 \frac{2(x_i - m_{ij})}{\sigma_{ij}^2} \quad (11)$$

$$\Delta \sigma_{ij} = -\frac{\partial E_p}{\partial \sigma_{ij}} = \delta_j^2 \frac{2(x_i - m_{ij})^2}{\sigma_{ij}^3} \quad (12)$$

$$\delta_j^2 = \delta_j^3 \mu_{ij}(x_i) \quad (13)$$

$$\delta_j^3 = \begin{cases} \sum_k \delta_k^4 \frac{\pi_k}{s^2} & k \neq j \\ \sum_k \delta_k^4 \frac{s - \pi_k}{s^2} & k = j \end{cases} \quad (14)$$

$$\delta_j^4 = \bar{\pi}_j (Y_k - y_k) w_{jk} \quad (15)$$

在训练中,规则数从 1 开始增加,直到找到一个满意的网络性能。选择适应的参数 \$\eta\$ 和 \$\alpha\$ 不是很容易的事;为了让目标函数极小,学习速率 \$\eta\$ 的选择应该足够小,但小的学习率将使收敛很慢;反之,若选择大的学习率,又可能引起学习过程的振荡,会收敛不到期望的值,另外由于目标函数是非线性的,会存在局部极小值^[2-3]。

为此,本文采用变步长的方法:首先设置一个初值,若依次叠代后误差函数 \$E\$ 增大,说明选择的 \$\eta\$ 过调,则将步长乘以一个小于 1 的常数 \$\beta\$;若依次叠代后的误差函数 \$E\$ 减少了,则所选的 \$\eta\$ 值过于保守,将步长乘以一个大于 1 的常数 \$\gamma\$。这样使得计算量不会增加太多,又使得步长得到合适的调整。步长调整关系为

$$\eta = \begin{cases} \beta \eta & \text{当 } \Delta E > 0 \text{ 且 } \beta < 1 \\ \gamma \eta & \text{当 } \Delta E < 0 \text{ 且 } \gamma > 1 \\ \eta & \text{其他} \end{cases} \quad (16)$$

其中 \$\beta, \gamma\$ 为常数, \$\Delta E = E(n) - E(n-1)\$。

4 ATP 仿真计算

4.1 ATP 模型的建立

本文采用 500 kV, 300 km 的双端电源系统,如图 3 所示,其正序参数分别为 \$Z_{1M} = 1.0515 + j43.176 \Omega\$, \$r_1 = 0.02083 \Omega/\text{km}, l_1 = 0.8984 \text{ mH}/\text{km}, C_1 = 0.01291 \mu\text{F}/\text{km}, Z_{1N} = 1.0515 + j43.176 \Omega\$; 零序参数分别为 \$Z_{0M} = j29.0925 \Omega, r_0 = 0.1148 \Omega/\text{km}, l_0 = 2.2886 \text{ mH}/\text{km}, C_0 = 0.00523 \mu\text{F}/\text{km}, Z_{0N} = j37.47 \Omega\$。在 ATP 仿真中,采用分布参数线路模型,系统的频率为 50 Hz,采样频率为 1 kHz。

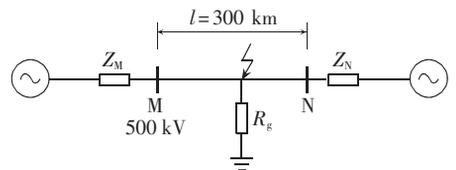


图 3 双端电源系统的仿真模型

Fig.3 Simulation model of a dual power source system

4.2 模糊神经网络的训练和测试

训练样本的选取影响学习后的模糊神经网络模型的推广能力,在选取样本时应考虑各种情况下的故

障模型。故障后的原始数据采用 ATP 仿真获得,并用全周傅氏算法提取可以反映故障特征的故障第 1 周电气量的基频分量作为网络输入向量。由于在不同故障条件下,直接计算的电气量具有很大的离散性,为了避免神经元输入数据过大而造成神经元饱和,把输入样本归一化到 $(-1,+1)$ 的区间内^[9-10]。

为了使网络具有更大的适应性,因此样本的选取应该尽量覆盖各种故障情况。考虑各种不同的故障条件,运用 ATP 对系统进行仿真计算。影响故障的因素有 5 个。

a. 线路两侧的电势夹角。令 $k \angle \delta = E_M / E_N$, 其中 δ 值反映系统负荷的变化, δ 值分别取 $0^\circ, 30^\circ, 60^\circ, 90^\circ, 120^\circ$, k 值取 1, 即不考虑两侧电势幅值差。

b. 故障类型的选择。包括单相接地短路(AG, BG, CG), 两相短路(AB, BC, CA), 两相接地故障(ABG, BCG, CAG), 三相短路(ABC 或 ABCG)。

c. 过渡电阻的选择。接地电阻 R_g 的取值范围为 $0 \Omega, 100 \Omega, 200 \Omega$; 相间电阻 R_l 的取值范围为 $0 \Omega, 25 \Omega, 50 \Omega$ 。

d. 对端系统阻抗 Z_N (80%, 100%, 120% 额定系统阻抗)。

e. 故障点的选择(以保护安装侧为准)。选用线路模型全长为 300 km, 训练样本为每隔 10 km 设一个故障点, 在线路两端多取点, 即为: 0 km, 5 km, 10 km, 15 km, 20 km, 30 km, …… , 270 km, 280 km, 285 km, 290 km, 295 km, 300 km 共 35 个故障点。

经过以上 5 种变化因素的排列组合, 形成了具有 25 200 个样本的训练样本集。

故障识别网络输出层的神经元由表示“a”, “b”“c”三相以及表示接地的“g”组成, 用“1”或“0”表示该相是否发生故障, 同样, “1”表示故障接地, “0”表示不接地, 例如当发生 A 相接地故障时, 输出向量 $y = [1, 0, 0, 1]$, AC 相间故障时, $y = [1, 0, 1, 0]$ 。仿真结果表明得到的值不为理想的“1”或“0”, 若其绝对值大于 0.5, 表示发生故障, 反之则表示无故障。

在训练过程中, 当满足误差精度要求或者迭代次数达到最大的设定次数时, 则停止训练。重新选取测试样本, 对得到的网络进行测试, 结果表明故障类型识别正确率达到 100%, 测距精度也满足输电线路要求, 表 1、表 2 给出了仿真得到的部分测试结果。

表 1 故障类型识别结果

Tab.1 Sectional test results of fault type identification

故障类型	a	b	c	g
ag	0.9489	0.1265	0.1365	0.9798
bg	0.1991	0.9815	0.1730	1.1015
cg	0.1503	0.0118	0.9864	0.9934
ab	1.0834	0.9573	-0.1431	0.0438
ac	0.9631	0.1548	0.9967	0.0545
bc	-0.0437	0.9758	1.0835	0.0485
abg	0.9991	1.0289	0.1121	1.0432
acg	1.0532	0.1783	0.9439	1.0320
bcg	0.0248	0.9899	1.1030	0.9538
abcg	0.9930	1.1062	0.9612	0.9883

表 2 单相接地故障测距子网络测试结果
(取过渡电阻 10Ω , 对端相角 30°)

Tab.2 Sectional test results of LG fault locating sub-network (transition resistance 10Ω , angle difference 30°)

l/km	h	h'	$\varepsilon/\%$	l/km	h	h'	$\varepsilon/\%$
10	0.0333	0.0375	0.42	160	0.5333	0.5305	0.28
20	0.0667	0.0606	0.61	170	0.5667	0.5636	0.31
30	0.1000	0.0969	0.31	180	0.6000	0.5992	0.08
40	0.1333	0.1392	0.59	190	0.6333	0.6311	0.22
50	0.1667	0.1646	0.21	200	0.6667	0.6657	0.10
60	0.2000	0.2030	0.30	210	0.7000	0.6984	0.16
70	0.2333	0.2381	0.48	220	0.7333	0.7307	0.26
80	0.2667	0.2639	0.28	230	0.7667	0.7666	0.01
90	0.3000	0.2979	0.21	240	0.8000	0.7985	0.15
100	0.3333	0.3304	0.29	250	0.8333	0.8339	0.06
110	0.3667	0.3648	0.19	260	0.8667	0.8719	0.52
120	0.4000	0.3971	0.29	270	0.9000	0.9080	0.80
130	0.4333	0.4300	0.33	280	0.9333	0.9348	0.15
140	0.4667	0.4606	0.61	290	0.9667	0.9691	0.24
150	0.5000	0.4978	0.38	299	0.9967	0.9882	0.85

注: l 为实际长度; h, h' 分别为期望和实际输出值(输出为故障距离与线路全长的比值); ε 为相对误差。

5 结语

本文提出了基于模糊神经网络的故障测距方法, 从仿真结果看出, 故障测距结果体现了故障测距子网络良好的适应性能, 其测距精度较高, 测距精度不受故障类型、过渡电阻、系统运行方式、故障点位置、对端系统阻抗等的影响, 克服了传统测距方法的缺点, 具有很好的推广性。

参考文献:

- [1] 张乃尧, 阎平凡. 神经网络与模糊控制[M]. 北京: 清华大学出版社, 1998.
- [2] 赵振宇, 徐用懋. 模糊理论和神经网络的基础与应用[M]. 北京: 清华大学出版社, 1995.
- [3] 李晓忠, 汪培庄, 罗承忠. 模糊神经网络[M]. 贵州: 贵州科技出版社, 1991.
- [4] 曹谢东. 模糊信息处理及应用[M]. 北京: 科学出版社, 2003.
- [5] 毛鹏, 孙雅明, 张兆宁. 具有冗余神经元神经网络模型系统的输电线路故障测距的研究[J]. 中国电机工程学报, 2000, 20(7): 28-33.
- [6] MAO Peng, SUN Ya-ming, ZHANG Zhao-ning. Study of fault location for high voltage over-head transmission line using neural networks model system with redundant neuron [J]. **Proceedings of the CSEE**, 2000, 20(7): 28-33.
- [6] 张兆宁, 毛鹏, 郁惟镛, 等. 基于组合神经网络的输电线路故障类型识别[J]. 继电器, 2001, 29(4): 1-5.
- ZHANG Zhao-ning, MAO Peng, YU Wei-yong, et al. The discrimination of the fault type of the transmission line based on combined neural network[J]. **Relay**, 2001, 29(4): 1-5.

(上接第 34 页 continued from page 34)

- [7] DASH P K, PRADHAN A K, PANDA G. A novel fuzzy neural network based distance relaying scheme[J]. **IEEE Transactions on Power Delivery**, 2000, 15(3):903-905.
- [8] SHU Hong-chun, SUN Xiang-fei, SI Da-jun. A new method for locating faults on transmission lines based on rough set and FNN[J]. **IEEE**, 2002, 4(10):2584-2588.
- [9] 余晓丹, 刘众仆, 王钢, 等. 应用模糊神经网络实现故障测[J]. **中国电力**, 1998, 31(3):10-13.
YU Xiao-dan, LIU Zhong-pu, WANG Gang, et al. Application of fuzzy neural network on fault location[J]. **Electric Power**, 1998, 31(3):10-13.
- [10] 魏远航. 基于模糊神经网络的变电站电压无功控制的研

究[D]. 广州:广东工业大学, 2001.

WEI Yuan-hang. Study of voltage-reactive power control on substations based on fuzzy neural network [D]. Guangzhou:Guangdong University of Technology, 2001.

(责任编辑:李玲)

作者简介:

刘凤霞(1978-),女,湖北孝感人,硕士研究生,研究方向为电力系统继电保护及安全监控(E-mail:yunmengfx@etang.com);

刘前进(1967-),男,湖北麻城人,副教授,主要从事电力系统继电保护研究与教学工作。

Fault locating based on fuzzy neural network

LIU Feng-xia^{1,2}, LIU Qian-jin¹

(1. Electric Power College of South China University of Technology, Guangzhou 510640, China; 2. Power Supply Bureau of Jieyang, Jieyang 522000, China)

Abstract: As affected by many uncertain factors of transmission lines, conventional fault locating methods can't locate the faults of transmission lines very well. A fault locating method based fuzzy neural network is proposed, which consists of layers of input, fuzzy, reasoning, de-fuzzy and output layers. It adopts variable steps to improve BP algorithm and quicken convergence speed. Simulation results show that it has good adaptability and high precision, and is not affected by different system operation modes, transition resistances and phase angle difference of two terminals.

Key words: transmission line; fault locating; fuzzy neural network; layered distribution