

基于波形识别的永久性和瞬时性故障的判别

郁惟镛, 胡炎, 黄登峰

(上海交通大学电力工程系, 上海 200240)

【摘要】 利用人工神经网络的波形识别功能解决了自适应重合闸中永久性故障和瞬时性故障的判别问题, 并且提出“循环训练法”以改善神经网络的收敛特性, 同时在提高网络的泛化能力方面也做了有益的探索。通过有导师的学习, 结合超高压输电线进行仿真计算及数据训练, 其结果表明: 经充分训练的网络可正确而快速识别永久性故障和瞬时性故障, 且不受故障点的位置、故障时的初相角、过渡电阻和系统运行方式的影响。

【关键词】 神经网络; 自适应重合闸; 波形识别; 永久性故障; 瞬时性故障

1 引言

在现代高压输电系统中, 单相接地故障是最常见的故障, 而单相自动重合闸 (SPAR) 针对这类故障, 可提高电力系统暂态稳定性, 减少对发电机轴系的冲击, 还可提高供电可靠性。能够判别故障类型是永久性还是瞬时性的自适应单相重合闸更是克服了传统单相自动重合闸可能重合于永久性故障的弊端。以前种种关于 SPAR 系统的研究、二次电弧的模拟以及计算机仿真都表明断路器断开后的暂态电压的波形与系统运行方式、故障条件等因素有关。实际系统中故障电压的波形还受到线路结构、参数, 故障前负荷以及大气环境等因素的影响, 因此利用传统方法很难实现单相自适应重合闸。近年来人工神经网络在电力系统其它领域取得了一些成功的应用, 解决了传统技术无法解决的问题, 也有利用神经网络来解决 SPAR 的例子。例如文^[1]利用付氏滤波算法得出故障分量来训练神经网络以区分永久性故障和瞬时性故障, 但它需要采集 20 个周波的电压波形并需要大量的前置处理。我们认为在现代高压系统中, 在故障发生 0.4s 以后再判别故障类型, 然后决定是否重合闸, 在系统可能已经失步的情况下, 即使是瞬时性故障, 也无异于重合于永久性故障。因此本文尝试利用人工神经网络来研究快速自适应重合闸的可能性。

众所周知, 在单相接地故障中, 如果是瞬时性故障, 那么故障点熄弧后, 故障相电压由耦合电压和电感电压组成, 称为恢复电压; 而永久性故障的故障相电压则无恢复电压, 然而仅仅依靠比较电压大小的电压判据是无法正确区分永久性故障和瞬时性故障的 (参见文^[3])。从实际电力系统的故障录波图可知, 瞬时性故障的恢复电压波形与永久性故障的接

地电压波形是有区别的, 在无法用逻辑判据来描述两者波形差别时, 利用神经网络来识别故障类型不失为一种明智的选择。人工神经网络所具有的信息分布式存储、大规模自适应并行处理、高度的容错性等是其可用于图象处理的基础。本文正是把故障波形输入神经网络, 利用其强大的图象处理能力来识别故障类型。所建网络通过对特征波形的学习, 能在故障发生后 160ms 内自适应地识别故障类型, 大大缩短了判别时间。

2 算法的基本原理

目前, 判别永久性和瞬时性故障的方法有许多种, 传统的方法一般是通过某种方式获得一个特征量, 利用该特征量与整定的阈值进行比较来判别故障类型。不同的判别方法对应于不同的特征量获取方式。如文^[3]通过分析一定假设条件下系统的等值电路, 得到断路器跳开后故障相线路侧电压近似值作为判据的特征量; 文^[4]利用小波变换分析故障电流, 得到故障电流的能量谱作为判据的特征量。然而, 故障后系统的电气量 (电压或电流) 中包含着大量故障特征信息, 仅仅通过某种方式得到的特征量虽在一定程度上反映了瞬时性和永久性故障的区别, 但是实际上已经损失了许多有价值的信息。因此, 这类方法从基本原理上就有先天的不足。

同传统的方法相比, 本文提出直接利用恢复电压波形来判别故障类型, 则完全避免了故障特征信息的损失, 从基本原理上就有明显的优越性。众所周知, 恢复电压波形受系统运行方式、故障点位置、故障发生时的初相角、过渡电阻、故障类型等因素的影响 (见图 2)。仿真的结果表明, 在故障类型不同时, 瞬时性故障消失后断开相线路侧电压波形 (恢复电压波形) 与永久性故障时在电压幅值、周期等方面

有明显的区别。然而,这种区别又不能简单地用某种特征量与已整定阈值的比较来完全区分,因此本文把神经网络作为一个黑匣子,将故障点熄弧后约半周波后的一个周波的恢复电压波形(每周采 20 点数据)送入人工神经网络,利用其波形识别功能判别故障类型。若故障为瞬时性的,则网络理想输出为 1;若故障为永久性的,则网络理想输出为 0。但是,由于恢复电压波形不仅仅受故障类型的影响,因此为了使神经网络的输出仅仅对故障类型敏感,必须在网络结构、学习算法、样本空间等方面进行合理的设计。

3 神经网络的学习算法

3.1 改进 BP 算法

在神经网络的学习算法中,反向传播算法(Back-Propagation)是一种较为成熟的算法,并取得了不少成功的例子。因此本文也采用以该算法为基础的改进 BP 算法,并为此构造了一个三层前馈网络,输入节点 X_1, X_2, \dots, X_n , 中间层输出为 h_1, h_2, \dots, h_n , 输出层为 y_1, y_2, \dots, y_n 。

改进 BP 算法实现的步骤如下:

(1) 将各权值赋一个小的随机数,可用均匀分布的随机数,这样可保证网络不被大的加权值所饱和;

(2) 从训练样本集中取一训练对,把输入矢量用作网络的输入;

(3) 计算网络输出矢量;

$$S_{1j} = \sum_i W_{ij} X_i$$

$$h_j = F(S_{1j}) = 1 / (1 + \exp^{-S_{1j}})$$

$$S_{2k} = \sum_j W_{jk} h_j$$

$$y_k = F(S_{2k}) = 1 / (1 + \exp^{-S_{2k}})$$

(4) 计算网络输出矢量与训练样本集中对目标的误差;

$$E = \sum_k (T_k - y_k)^2$$

其中 T_k 是理论值,即目标值;

(5) 从输出层反向计算到第一中间层,用下降梯度法和附加冲量法调整网络权值;

$$W_{jk}(n+1) = \alpha_1 h_j + W_{jk}(n)$$

$$\alpha_1 = y_k(1 - y_k)(T_k - y_k)$$

$$W_{ij}(n+1) = \alpha_2 X_i + W_{ij}(n)$$

$$\alpha_2 = h_j(1 - h_j) \sum_k \alpha_1 W_{jk}$$

其中 α 称为学习率,一般取 0.01 ~ 1, β 称为冲量系数,一般取 0.9 左右;

(6) 对训练样本集中每一样本重复上述(2) ~ (5)步,直至总误差收敛至一定精度。

为了改善网络的收敛特性,本文还将模拟退火技术融入了该算法。

3.2 循环训练法

BP 算法存在着收敛速度慢,可能收敛至局部最优等等问题,在实际应用中,本文结合一种循环训练法来训练网络,效果很好。具体操作步骤如下:首次训练时,网络权值赋随机数,用一有代表性的子样本集训练网络,使其收敛,然后以这组训练过的网络权值为初值,对扩大后的子样本集再重新训练,使其收敛,如此循环,直至使整个样本集收敛。我们认为这种方法有一定的理论基础,即小的样本集容易使网络收敛,然后每次赋初值时采用以前的训练结果,使网络一开始即处于最优附近,这样在下次训练时能有效地避免陷入局部最优。这种方法在实践中被证明是行之有效的。如本文若一次对 30 个样本进行训练,网络陷入瘫痪状态,而采用分批追加样本的循环训练法却能有效地收敛。

4 仿真系统的建立

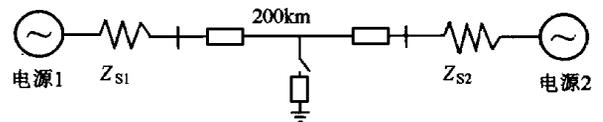
本文选取了如图 1 所示的双侧电源单回线路来进行自适应重合闸方案的研究,其中线路上的故障是用一个开关串一个电阻来控制的。这主要是考虑到在不影响问题性质的前提下 EMTP 仿真的方便。

故障发生时刻 t_0 :0ms

两端断路器跳开时刻 t_1 :80ms

瞬时性故障时,故障消失时刻 t_2 :120ms

神经网络计算开始时刻 t_3 :130 ~ 135ms



$$Z_{s1}: X_0 = 537.0, X_1 = 166.7$$

$$Z_{s2}: X_0 = 169.3, X_1 = 84.7$$

$$\text{电源 1: } 550\text{kV}; \text{ 电源 2: } 525\text{kV}$$

$$\text{线路: } Z_0 = 0.1717 + j0.6407 / \text{km}, C_0 = 0.0021\mu\text{F/km}$$

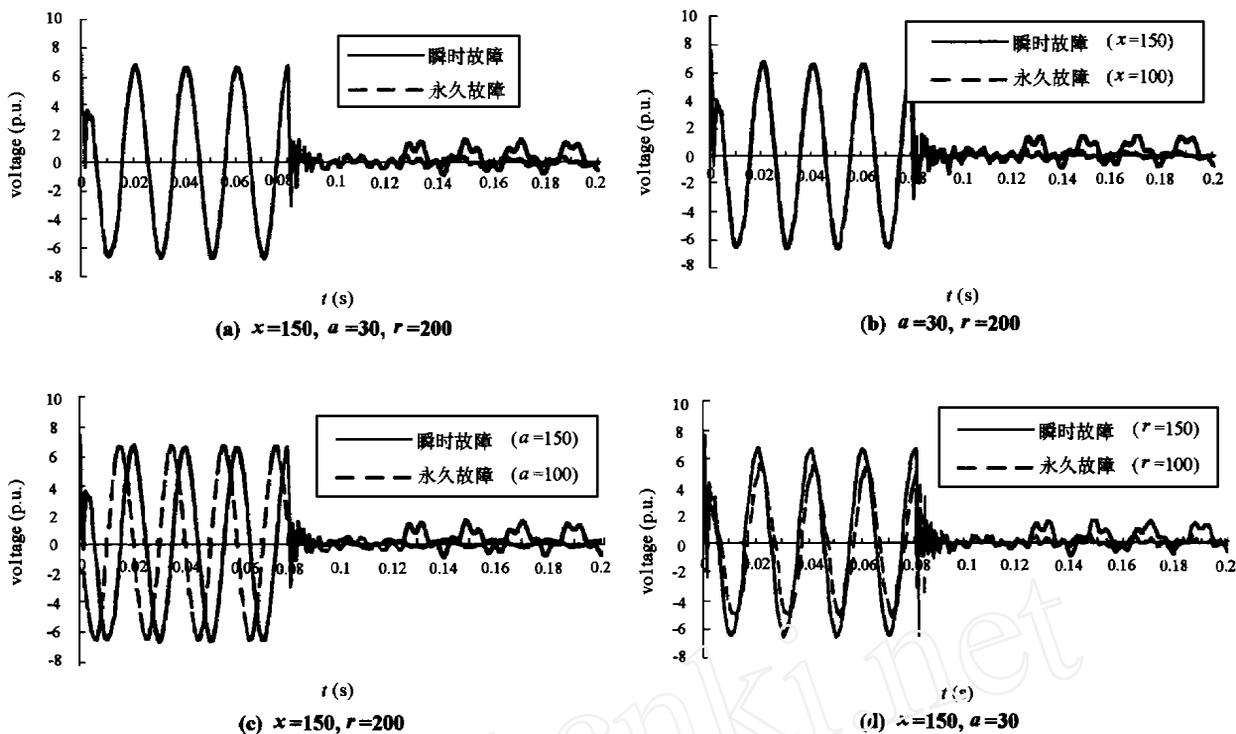
$$Z_1 = 0.02 + j0.28 / \text{km}, C_1 = 0.0129\mu\text{F/km}$$

t_1 :故障相线路两侧开关跳开; t_2 :模拟故障的接地开关跳开

图 1 仿真系统模型及参数

5 网络的训练和测试

本文建立了一个三层前馈神经网络。因为本文



其中 x 表示故障点离电源一的距离,单位为公里;
 a 表示故障发生时电源电压的相位,单位为度;
 r 表示过渡电阻,单位为欧姆;
 故障发生时刻: 0ms;
 故障相两端断路器跳开时刻: 80ms;
 故障点完全熄弧时刻: 120ms

图2 永久性和瞬时性故障时断开相电压波形的比较

采用的是基于波形识别的方法,利用的是瞬时性故障和永久性故障的电压波形,故直接将电压波形经采样后输入网络,采样频率为1000Hz,数据窗长度为20ms,因此输入节点20个,中间层节点35个,输出节点1个,构成一个20-35-1的神经网络。

5.1 训练样本集的构造和训练结果

选取训练样本时,考虑了以下故障情况:

1. 故障地点的取值范围为:50km,100km,150km
 2. 过渡电阻的取值范围为:10,200
 3. 故障发生时初相的取值范围为:1/4周期,1/2周期,3/4周期
 4. 故障类型为:瞬时性故障,永久性故障
- 经以上四种情况的排列组合,形成了具有36个样本的训练样本集。

将此训练样本集输入20-35-1的神经网络,网络训练精度很高,训练样本集的总误差可达0.001。

5.2 测试样本集的构造和测试结果

网络训练的目的在于使网络能识别未知故障,基于波形识别的快速自适应单相重合闸方案的可行与否也在于网络是否能正确判别未知故障。测试样本集的选择考虑了系统的不同运行方式,过渡电阻

分为1、50、300等几种,故障发生时的初相分为1/10周期、7/20周期、17/20周期三种,故障地点分为20km、120km、170km等几种,故障类型分为永久性故障和瞬时性故障。这几种情况的组合形成具有37个样本的测试样本集。

表1

(瞬时性故障时,神经网络理想输出为1;永久性故障时,神经网络理想输出为0)

网络结构	训练后的测试结果
20-20-20-1	一瞬时性故障输出为0.032610,其余误差绝对值<0.1
20-15-10-1	一瞬时性故障输出为0.768444,其余误差绝对值<0.1
20-10-5-1	一瞬时性故障输出为0.324538,其余误差绝对值<0.1
20-15-5-1	一瞬时性故障输出为0.808591,其余误差绝对值<0.1
20-15-15-1	一瞬时性故障输出为0.665342,其余误差绝对值<0.1
20-15-2-1	一瞬时性故障输出为0.824220,其余误差绝对值<0.1
20-10-2-1	一瞬时性故障输出为0.701570,其余误差绝对值<0.1
20-10-3-1	一瞬时性故障输出为0.123894,其余误差绝对值<0.1
20-20-1-1	一瞬时性故障输出为0.844880,其余误差绝对值<0.1
20-20-2-1	所有故障输出误差绝对值<0.1
20-25-2-1	所有故障输出误差绝对值<0.1

将此测试样本集输入网络进行测试,结果基本令人满意,但有一个瞬时性故障被误判为永久性故障

障。通过分析,发现这主要有两方面的原因:一是网络的泛化能力不强;二是这个测试样本离训练样本集较远,以致于训练样本集不能将其覆盖。为此,本文并没有简单地通过扩大训练样本集来达到良好的测试效果,而是通过优化网络的结构以提高网络的泛化能力,进而达到要求的测试目标。

6 网络泛化能力的改善

为了提高网络的泛化能力,本文将原来的 20-35-1 三层网络扩大为四层网络,即增加一层隐含层。网络结构选择四层,主要是考虑到缩减网络的规模。因为往往一个三层网络需要大量的隐含层节点,而一个四层网络只需要较少的隐含层节点即可解决问题;另外,增加层数可使网络的表达能力更强,这对于直接处理波形识别这种问题显然是有利的。但是,隐含层节点数的选取具有很大的随机性。一般来说,如果网络规模太小,则不能对问题形成一个好

的解,导致网络学习失败;如果网络规模太大,不但计算量迅速增大,而且可能会有无数个与训练数据相关的解,使网络的泛化能力很差。本文对四层网络隐含层节点数做了试探性的改动,并用于训练和测试,具体结果见表 1。

从表 1 可以看出,输出结果对第二中间层的节点数比较敏感,多或少都会使输出结果波动较大,而以 2 个节点最为合适。相对而言,第一中间层节点数只要不小于 20 即可较好地表达问题,因此最终我们选取了 20-20-2-1 网络结构,用 36 种样本进行训练后,又用不同于训练样本的 37 种测试样本进行测试,结果见表 2。从中可以看出,这样的网络结构是比较合理的,即能较好地表达问题,又能获得比较满意的泛化能力。由此也可以证明,基于波形识别的快速自适应单相重合闸方案是可行的,有着十分广阔的应用前景。

表 2

(瞬时性故障时,神经网络理想输出为 1;永久性故障时,神经网络理想输出为 0)

理想输出	网络输出	理想输出	网络输出	理想输出	网络输出 (*E-2)	理想输出	网络输出 (*E-2)
1	0.994372	1	0.981074	0	0.442718	0	0.411164
1	0.995595	1	0.995264	0	0.433741	0	0.402583
1	0.995764	1	0.995193	0	0.472058	0	0.778631
1	0.994507	1	0.994511	0	0.517203	0	0.411720
1	0.994558	1	0.994633	0	0.500150	0	0.413146
1	0.993442	1	0.994724	0	0.540859	0	0.493360
1	0.993257	1	0.994490	0	0.402583	0	0.790076
1	0.993676	1	0.994534	0	0.402583	0	0.718763
1	0.993157	1	0.985272	0	0.402583	0	0.871417
1	0.994306						

7 结论与展望

1) 本文提出了一种直接根据故障电压波形来识别故障类型的新型重合闸方案,经仿真计算表明,该方案是切实可行的,有着十分广阔的应用前景。

2) 本文采用以 BP 算法为核心的改进算法。实践表明,本算法采用动量项、变斜率及模拟退火技术后,能有效克服 BP 算法存在的收敛速度慢、收敛特性差等缺点,使训练获得满意结果。

3) 本文对神经网络的结构优化进行了探讨,通过试探性调整,使网络的泛化能力增强,能全部正确识别测试样本。

4) 实践表明网络对于永久性故障和瞬时性故

障的泛化能力是不一样的。对永久性故障未发现误判情况,而对瞬时性故障则相对容易误判,因此在训练样本构成中可以适当向瞬时性故障倾斜。

5) 可进一步对断路器跳闸时间和瞬时故障消失时间作模糊化处理,使网络具有更广的适用范围。

[参考文献]

- [1] 郁惟镛,潘荣贞,李翔,黄浩. 神经网络在自适应单相重合闸中的应用研究. 全国高等学校电力系统及其自动化专业第十三届学术年会论文集. :1136-1141.
- [2] 施鸿宝. 神经网络及其应用. 西安交通大学出版社.
- [3] 葛耀中. 新型继电保护与故障测距原理与技术. 西安交通大学出版社.

(下转第 17 页)

如图 3 所示,假定开关 1、3 双回运行定值与 5、7 单回运行定值配合,分支系数由以下 4 个中选取:

回挂检, I_1/ I_7 、 I_3/ I_7 ;

回挂检, I_1/ I_5 、 I_3/ I_5 。

3) 单回运行定值与双回运行定值配合

如图 3 所示,假定开关 1、3 单回运行定值与 5、7 双回运行定值配合,分支系数由以下 4 个中选取:

回挂检, I_3/ I_7 、 I_3/ I_5 ;

回挂检, I_1/ I_7 、 I_1/ I_5 。

4) 单回运行定值与单回运行定值配合

如图 3 所示,开关 1、3、5、7 单回运行定值,开关 1、3 与 5、7 配合时,分支系数由以下 4 个中选取:

回挂检, 回挂检, I_3/ I_7 ;

回挂检, 回挂检, I_3/ I_5 ;

回挂检, 回挂检, I_1/ I_7 ;

回挂检, 回挂检, I_1/ I_5 ;

5 程序框图

5.1 总框图见图 4。

5.2 段框图见图 5。

5.3 段框图见图 6。

6 结束语

本程序自动化程度高,计算速度快,在湖北电网使用效果很好,原来湖北全网 220kV 和 110kV 线路零序电流保护整定计算由几个人完成还很紧张,现在一个人就可轻松完成,大大地提高了工作效率。因我们水平有限,望同行多提宝贵意见。

收稿日期:1998—12—25

作者简介:王广学(1955 -),男,大学本科,研究方向为电力系统继电保护与自动化。

BRAINPOWER ZERO-SEQUENCE CURRENT PROTECTION SETTING PROGRAM FOR POWER SYSTEM LINE

WANG Guang-xue, FENG Ling, WANG You-huai

(Hubei Province Power Dispatch Communication Bureau, Hubei Wuhan 430077, China)

Abstract Main functions and characteristic for zero sequence current protection setting program are presented in this paper. Ways of no-balance zero sequence current for double lines are introduced.

Key words brainpower; zero sequence current protection; setting program

(上接第 13 页)

[4] F Jiang, Z O Bo, O X Yang. The Wavelet Transform Applied to Distinguish between Transient and Permanent Faults. 1998 International Conference on Power System Technology Proceedings, Beijing China, 1998, 2:1116.

收稿日期:1998—12—28

作者简介:郁惟镛(1940 -),男,博士生导师,教授,研究方向为人工智能在电力系统中的应用; 胡炎(1975 -),男,硕士,研究方向为人工智能在电力系统中的应用; 黄登峰(1976 -),男,本科生,电力系统自动化专业。

RESEARCH OF SELF-ADAPTIVE RECLOSE BASED ON WAVE IDENTIFICATION

YU Wei-yong, HU Yan, HUANG Deng-feng

(Electric Power Department of Shanghai Jiaotong University, Shanghai 200240, China)

Abstract This paper deals with the problem of identification between permanent fault and transient fault in self-adaptive reclose using the wave identification function of artificial neuron network, and brings forward a circular-training method in order to improve the convergency feature of neuron network. At the same time, it makes a meaningful probe in improving the generalization feature of neuron network. After the supervised study, the digital simulation and data training of superhigh voltage transmission line, the results indicate that the well-trained neuron network is able to identify permanent fault and transient fault correctly and quickly. Furthermore, it isn't effected by fault location, initial-phase angle at the time of faults outbreak, transition resistance and system operation mode.

Key words artificial neuron network; self-adaptive reclose; wave identification