

检测电压瞬时脉冲扰动的小波—神经网络新方法

王 晶¹, 束洪春², 陈学允¹

(1. 哈尔滨工业大学, 黑龙江省哈尔滨市 150001; 2. 昆明理工大学, 云南省昆明市 650051)

摘要: 对动态电能质量暂态扰动中的电压瞬时脉冲扰动进行了分析, 提出了一种基于小波—神经网络的电压瞬时脉冲扰动识别的新方法。首先讨论了电压瞬时脉冲扰动产生的原因, 用 PSCAD/EMTDC 软件包实现电压瞬时脉冲扰动的暂态仿真。然后, 选用 db4 小波并将扰动波形进行 4 尺度的小波分解, 以分解后各层的能量作为 3 层概率神经网络(PNN)的输入特征矢量, 从而正确地把雷击和开关动作造成的扰动区分开。仿真结果表明, 与传统的基于电压幅值/有效值的扰动识别方法相比, 该方法不但能正确区分各种扰动, 且能对不同原因造成的扰动进行正确分类。

关键词: 电能质量; 瞬时脉冲扰动; 小波变换; 人工神经网络

中图分类号: TM935

0 引言

电能质量的下降会影响电力设备的运行, 造成遥控误动、电缆过热、变压器中涡流损耗增加、保护误动以及电表测量错误等异常现象。尤其是诸多电子设备一方面对所提供电压很敏感, 另一方面又是电能质量下降的主要原因^[1]。

电能质量检测管理主要从以下 3 个方面进行: ①对用户方, 考虑扰动对用电设备的冲击; ②对设备制造方, 了解扰动的程度及发生的频率, 以确定设备的抗干扰能力, 同时生产电网允许并对电网污染最小的设备; ③对供电方, 同时考虑扰动对用户设备的影响, 以及用户产生的扰动对其他用户或电网的影响。

传统的电能质量暂态扰动的检测方法通过对相邻 2 个周期的波形进行点对点比较来实现, 当比较的结果超过整定值, 则说明发生了这一类的扰动^[2]。但这种方法无法检测波形的周期性变化(如周期性的谐波、平顶波等)。文献[3]使用 ANN 技术对扰动进行识别, 这种方法可以识别某些特定的扰动, 但一个 ANN 只能识别一种扰动, 这使它在应用时受到很大的局限。文献[4]同样使用 ANN 技术, 达到对多种扰动准确识别的目的, 但是该方法的输入样本数据过大, 且可能导致不收敛。

本文采用 Neuralshell® 2 推荐的对分类具有

最好效果的 3 层概率神经网络(probabilistic neural network, 缩写为 PNN), 以小波分解后各层的“能量”作为输入, 对电压瞬时脉冲扰动进行检测。结果表明, 该方法不但能大大减小样本的输入量, 且能保证波形的正确识别。

1 小波变换基本原理

在小波理论中, 任一函数 $x(t)$ 被分解为一系列小波的组合形式。其中每一个小波均通过对一小波母函数 $\Psi(t)$ 进行伸缩和平移而实现。一般而言, 小波母函数是一振荡、能量有限且均值为 0 的函数。连续小波变换(CWT)用公式表示为:

$$W_{\Psi}(a, b) = \frac{1}{\sqrt{|a|} \int_{-\infty}^{+\infty} x(t) \Psi^* \left(\frac{t-b}{a} \right) dt} \quad (1)$$

式中, 尺度参数 a 和时间中心参数 b 为实数, $a \neq 0$; Ψ^* 为 Ψ 的共轭; $W_{\Psi}(a, b)$ 为小波系数。

实际计算中, 常将式(1)中的参数 (a, b) 离散化, 其中最为著名的是离散二进小波变换, 即将连续小波变换进行二进制离散, 使 $a = 2^k, b = 2^k j; k, j \in \mathbb{Z}$ 。对应的小波函数为:

$$\Psi(j, k) = 2^{-\frac{j}{2}} \Psi(2^{-j}t - k) \quad (2)$$

重构公式为:

$$x(t) = \sum_{j \in \mathbb{Z}} \sum_{k \in \mathbb{Z}} W_{\Psi}(2^k, 2^k j) \Psi(j, k) \quad (3)$$

2 暂态仿真

瞬时脉冲(surge)表示在 2 个连续稳态之间的一种持续时间极短(μs - ms 级)的数量变化现象。瞬时脉冲可以是任一极性的单方向脉冲, 也可以是发生在任一极性的阻尼振荡波的第 1 个尖峰^[5]。

收稿日期: 2001-10-16; 修回日期: 2001-12-17。

云南省科技攻关项目(2000B2-02)、云南省应用基础研究项目(98E0409M, 99E006G)及云南省中青年学术和技术带头人培养经费资助项目。

直击雷和开关动作是产生瞬时脉冲的直接原因。雷击将使电路中产生一个额外的注入电流,此电流流经接地阻抗时导致电压瞬时脉冲的产生。另外,供电方进行保护动作、切负荷或系统运行方式改变等开关动作,甚至用户的简单操作(如开空调)也将产生瞬时脉冲。

本文使用 PSCAD/EMTDC 软件包,对直击雷和开关动作造成的扰动进行仿真。

被仿真的系统基本参数为:变压器选用 S9-500/10 型 10 kV 双绕组变压器,额定电压为 10 kV : 400 V,空载损耗为 1 kW,阻抗电压为 4%,联结组标号为 Y-yn0;10 kV 输电线为 LGJ-25/4 型的 15 km 单回路,由于架空线路不超过 300 km,所以线路参数用集中参数表示,正序电阻值为 1.26 Ω /km,正负序电抗值为 0.399 Ω /km,零序电抗为 1.396 5 Ω /km,零序电阻值为 1.41 Ω /km。

2.1 雷击

设输电线的 C 相 0.03 s 时在距变压器 7 km 处遭雷击,电路结构如图 1 所示。




图 1 系统遭雷击示意图

Fig. 1 Schematic diagram of lightning strike on system

图 1 中,注入电流用方程表示为:

$$i_{lj} = e^{-20\,000t} - e^{-1\,666\,666t} \quad (4)$$

波形示于图 2。




图 2 注入电流波形

Fig. 2 Lightning current waveform

此时在线路 380 V 侧测得的电压波形如图 3 所示。

2.2 开关动作

由于输电线路瞬时性故障,使系统中 C 相自动重合闸(图 4 中 BC 所示)在 0.03 s 动作,0.5 s 重合闸成功。电路结构如图 4 所示。此时在 380 V 侧测得的电压波形示于图 5。




图 3 高压线遭雷击对负荷端三相电压的影响

Fig. 3 Surge of load side caused by lightning strike to high-voltage line




图 4 系统 C 相重合闸动作示意图

Fig. 4 Schematic diagram of reclosing on C-phase




图 5 自动重合闸对负荷端三相电压的影响

Fig. 5 Surge of load side caused by reclosing

3 小波-神经网络检测方法

3.1 总体框图

小波-神经网络检测方法的总体流程图如图 6 所示。

在得到电压瞬时脉冲扰动的暂态波形后,选择适当的时窗和采样率对原始波形进行采样。本文以 20 kHz 的采样率对 5 个周期内的波形进行采样,共得到 2 000 个采样点。然后,选择一种小波母函数用来进行小波分解,并提取小波分解后的特征矢量作为 ANN 的输入。最后,用神经网络对输入特征矢量进行训练,得到检测结果。




图 6 瞬时脉冲波形检测流程图

Fig. 6 General framework of surge wave detection

3.2 小波分解与特征提取

3.2.1 小波分解

显然,传统的电能质量检测方法难以区分图 3 和图 5 的扰动原因。因此运用小波变换,以期得到各扰动的特征表示。

小波母函数的选择是小波应用的关键,也是小波应用中需进一步研究的工作。由于 Daubechies 小波对不规则信号较为灵敏,因而在电能质量分析中得到了广泛的应用。文献[6]指出,db4 小波相对于其他 db 小波,具有最短的时窗,因而具有比其他小波更好的时间分辨率。因此,本文用 db4 小波来对暂态波形进行 4 尺度^[7]下的分解分析。为了突出波形变化,同时降低噪声的干扰,取小波系数的平方值来分析。

图 3 和图 5 的小波分析结果如图 7 和图 8 所示。由图 7 和图 8 明显可见,扰动发生时小波系数的平方值远大于其他时刻的值,从而可检测到扰动发生的瞬时时刻为 0.03 s。但仍难以总结出这两种扰动的特征量。




图 7 图 3 中 A 相电压在 4 尺度下各小波系数平方值

Fig. 7 Squared wavelet coefficients of voltage A(in figure 3) at scale 4




图 8 图 5 中 A 相电压在 4 尺度下各小波系数平方值

Fig. 8 Squared wavelet coefficients of voltage A(in figure 5) at scale 4

3.2.2 特征提取

特征选择与提取的基本任务是如何从众多特征中找出那些最有效的特征来表示信号,既加强分类信息又压缩特征的数据量。

文献[4]用各尺度下小波系数的平方值作为特征量输入神经网络,效果良好,但需要复杂的神经网络结构。因为文献[4]需要的输入神经元个数为 496 个(256+128+64+32+16)。若提高采样率,则输入神经元还要增多。

本文基于以下事实,使用各尺度下的能量作为特征量:由于不同的扰动体现出的对各频率成分的抑制和增强作用不同,使相同频带内信号的能量有着较大的差别,它使某些频带内信号能量减小,而使另外一些频带内信号能量增大。因此,在各频率成分信号的能量中,包含着丰富的信息,某种或某几种频率成分能量的改变即代表了一种扰动情况。因此,可以利用这些能量进行模式识别^[8]。

本文中,以 $x_{ik}(i=1,2,3,4;k=1,2,\dots,2\ 000)$ 表示 4 个尺度下的单支重构信号的平方值,其中 i 表示 4 个尺度, k 表示各尺度下单支重构信号的个数,则各频带信号的总能量表示为:

$$E_i = \left(\sum_{k=1}^n x_{ik}^2 \right)^{\frac{1}{2}} \quad (5)$$

为了提高识别率,同时取高低压侧电压在 4 个尺度下的能量作为特征量,因此一个样本由 24 个(3(相)×2(边)×4(尺度))能量值构成,从而大大减小了输入量。

3.3 ANN 检测方法

模式识别的基本方法是基于最小错误率的贝叶斯决策方法。它需要先验统计知识,以使误判的概率最小。但大部分情况下先验知识不够甚至根本未知。神经网络则不需要先验概率,它能够从样本中

学习分类所需要的任意复杂的判别函数,并且能随着系统的变化不断学习,具有自适应能力。此特点被广泛用于各种故障的识别。

3.3.1 ANN 结构

采用 Neuralshell® 2 推荐的对分类具有最好效果的 3 层遗传自适应概率神经网络(PNN),结构如图 9 所示。神经网络的输入层、模式层和输出层节点数分别为 24,82 和 2。




图 9 概率神经网络的结构
Fig. 9 Structure of PNN

PNN 中,每一个输入都对应一个权系数。由于初始权系数对训练结果影响很大,因此选用遗传自适应学习,由 ANN 经训练后自己提供最优初权值。

另外,小波变换后得到的特征量并不能直接作为 ANN 的输入,必须转换到 ANN 工作的有效数值范围内。但线性变换可能由于特征量过大而使输入被截断或超出范围,造成仿真失败。因此,本仿真使用式(6)的变换关系,使所有的输入数据均被限制在(0,1)之间,从而避免由于数据被截断或超出范围而造成的误判或无法判断:

$$f(v_{\text{alue}}) = \frac{1}{1 + \exp(-(v_{\text{alue}} - m_{\text{ean}})/s_{\text{d}})} \quad (6)$$

式中, v_{alue} 为小波变换后提取的特征量; m_{ean} 为此样本数据的平均值; s_{d} 为这些数据的标准偏差; $f(v_{\text{alue}})$ 为变换后 ANN 的输入。

表 1 为训练好的扰动分类输出。

表 1 神经网络理想输出
Tab.1 Ideal output from ANN

扰动原因	神经网络输出	
雷 击	1	0
开关动作	0	1

3.3.2 训练与测试

82 个训练样本和 27 个测试样本完成 ANN 模块训练。训练样本为雷击和开关动作造成的含脉冲的电压波形,扰动时间步长为 0.000 5 s,因此一个工频周期内将形成 82 组样本。测试样本为不同时刻开关动作和不同强度、不同位置、不同时刻的雷击造成的 27 个电压扰动波形。测试结果示于表 2。

表 2 神经网络测试结果
Table 2 Testing results by ANN

样本 序列	扰动时 间/s	扰动位 置/km	扰动 幅度	扰动 类型	实际输出	
1	0.016 0	9	1.0	雷击	1	0
2	0.016 0	9	0.1	雷击	1	0
3	0.016 0	9	10.0	雷击	1	0
4	0.037 5	9	1.0	雷击	1	0
5	0.037 5	9	0.1	雷击	1	0
6	0.037 5	9	10.0	雷击	1	0
7	0.057 5	9	1.0	雷击	1	0
8	0.057 5	9	0.1	雷击	1	0
9	0.057 5	9	10.0	雷击	1	0
10	0.013 0	12	0.5	雷击	1	0
11	0.024 0	12	15.0	雷击	1	0
12	0.056 0	12	20.0	雷击	1	0
13	0.012 0	7	8.0	雷击	1	0
14	0.027 0	7	0.5	雷击	1	0
15	0.060 0	7	0.2	雷击	1	0
16	0.016 0	输电线	—	开关	0	1
17	0.057 5	输电线	—	开关	0	1
18	0.035 0	输电线	—	开关	0	1
19	0.043 0	输电线	—	开关	0	1
20	0.072 0	输电线	—	开关	0	1
21	0.003 0	输电线	—	开关	0	1
22	0.033 0	11	1.5	雷击	1	0
23	0.050 0	6	8.0	雷击	1	0
24	0.023 0	5	0.7	雷击	1	0
25	0.010 0	3	10.0	雷击	1	0
26	0.070 0	2	3.0	雷击	1	0
27	0.016 0	10	0.5	雷击	1	0

表 2 中,扰动位置指距离 10 kV 变压器的位置;扰动幅度指雷击时注入电流幅度与原线路电流幅度之比。由表 2 结果可见,本方法可正确、可靠地将雷击和开关动作造成的扰动分开。

3.3.3 采样率与时窗对训练结果的影响

上述电压瞬时脉冲扰动检测方法是在 20 kHz 采样率和 5 个周期长度下进行的。为了满足实际应用,以不同采样率对扰动进行不同时窗宽度的截断,得到的采样率和时窗对训练结果的影响见表 3。

表 3 采样率与时窗对训练结果的影响
Table 3 Effect of sampling rate and time-window on detection results

采样率/ kHz	时窗宽度 (周期)	检测结果	
		对	错
20	5	27	0
10	5	27	0
5	5	27	0
1	5	27	0
1	4	26	1
2	2	26	1
2	3	26	1

4 结论

本文对雷击和开关动作造成的电压瞬时脉冲扰动进行检测与识别。先对电压瞬时脉冲扰动进行暂态仿真并用 db4 进行 4 尺度下的小波分解。由于不同扰动在各频带内能量分布不同,本文利用小波分解后各频带内的能量作为 ANN 训练的特征输入,选用文献[5]推荐的对分类效果最好的 3 层遗传自适应概率神经网络,正确地把雷击和开关动作造成的扰动区分开。通过进一步分析比较,本文方法可以在采样率为 5 kHz 和小到 2 个周期的前提下得到良好的检测结果。作者将进一步将此方法应用于各类电能质量扰动的特征提取及其识别。

参考文献

- 1 Santoso Surya, Powers E J, Grady M W, et al. Power Quality Disturbance Waveform Recognition Using Wavelet-based Neural Classifier Part 1: Theoretical Foundation. IEEE Trans on Power Delivery, 2000, 13(1): 222~228
- 2 Dorr D S. Power Quality Study——1990 to 1995: Initial Results. In: IEEE Seventh Annual Applied Power Electronics Conference and Exposition. Boston: 1992
- 3 Kandil N, Sood V K, Khorasani K, et al. Fault Identification in an AC-DC Transmission System Using Neural Networks. IEEE Trans on Power Systems, 1992, 7(2): 812~819
- 4 Santoso Surya, Powers E J, Grady W M, et al. Power Quality

Disturbance Waveform Recognition Using Wavelet-based Neural Classifier Part 2: Application. IEEE Trans on Power Delivery, 2000, 15(1): 229~235

- 5 Kazibwe W E, Sendaula M H. Electric Power Quality Control Techniques. Van Nostrand Reinhold, 1993
- 6 Brito N S D, Souza B A, Pires F A C. Daubechies Wavelets in Quality of Electrical Power. In: The 1998 International Conference on Harmonics and Quality of Power. Athens (Greece): 511~515
- 7 Pires F A C, Brito N S D. The Analysis of Transient Phenomena Using the Wavelet Theory. In: Proceedings of the International Conference on Power Systems Transients. Seattle: 1997
- 8 胡昌华, 张军波, 夏 军, 等(Hu Changhua, Zhang Junbo, Xia Jun, et al). 基于 MATLAB 的系统分析与设计——小波分析(MATLAB-based System Analysis and Design——Wavelet Analysis). 西安: 西安电子科技大学出版社(Xi'an: Xidian University Publishing Company), 1999

王 晶(1974—),女,博士研究生,主要研究电力系统电能质量。E-mail: kmhelan@sina.com

束洪春(1961—),男,博士,教授,院长,国家自然科学基金项目评审专家,全国优秀教师。主要研究新型继电保护与故障测距、数字信号处理及其应用、电力系统 CTI 技术等。E-mail: hongchunshu@163.net

陈学允(1934—),男,教授,博士生导师,长期从事电力系统分析与控制及电力系统计算机应用等教学科研工作。

SURGE DISTURBANCE DETECTION USING WAVELET-BASED NEURAL NETWORK

Wang Jing¹, Shu Hongchun², Chen Xueyun¹

(1. Harbin Institute of Technology, Harbin 150001, China)

(2. Kunming University of Science and Technology, Kunming 650001, China)

Abstract: After carefully analyzing the voltage surge disturbances in the field of dynamic power quality issues, a new surge disturbance recognition method, based on wavelet theory and neural networks, is proposed in this paper. First the various causes of surge are discussed. Then the PSCAD/EMTDC software package is used for the simulation of the voltage transient processes with different disturbances. The simulated disturbance waves are then decomposed into 4 levers using wavelet transform. Afterwards, the energy feature, which is extracted from the wavelet coefficients under different levers, is employed as the input feature vector to probabilistic neural network (PNN) training. Results show that this method has a high accuracy to distinguish between surge disturbances caused by lightning and those caused by switching operation. Comparing to conventional voltage-based disturbance detection approaches, the proposed approach is precise not only in discriminating the type of transient event, but also in recognizing the causes of disturbances.

This work is jointly supported by Yunnan Science and Technology Research Projects (No. 2000B2-02), Yunnan Natural Science Foundation (No. 98E049M, 99E0006G) and the Foundation of Yunnan Province for Young Scholars in Science and Technology.

Key words: power quality; voltage surge; wavelet transform; ANN