

基于 LMD - 1 (1/2) 维谱熵 - Elman 神经网络 输电线路短路故障识别理论与方法

蔡明山¹, 蔡双², 周军³

(1. 湖南文理学院 电气与信息工程学院, 湖南 常德 415000; 2. 常德烟草机械有限责任公司, 湖南 常德 415000;
3. 国网江西省电力公司 宜春供电分公司, 江西 宜春 336000)

摘要:针对电力系统输电线路故障时短路电流的暂态特征,采用 LMD 对相模变换后的短路电流进行分解,得到一系列 PF 分量,然后计算前 8 个 PF 分量的 1(1/2) 维谱熵值作为特征向量,最后将构造的特征向量输入到已训练好的 Elman 神经网络中进行故障类型识别,并在 Matlab 平台上建立仿真模型. 仿真结果表明,采用的方法能够快速准确地判断出故障类型和故障相;与传统 BP 网络相比,该方法具有更快的识别速度、更高的识别率,并且识别结果不受过渡电阻、故障位置、相差角等线路参数的影响,因而,实用、有效.

关键词:输电线路;故障识别;LMD 分解;1(1/2) 维谱熵;Elman 神经网络

中图分类号: TM713 **文献标志码:** A **文章编号:** 1672-9102(2015)01-0078-09

Power system transmission line short circuit fault recognition theory and method based on LMD - 1 (1/2) dimension spectrum entropy - elman neural network

Cai Mingshan¹, Cai Shuang², Zhou Jun³

(1. School of Electrical & Information Engineering, Hunan University of Arts & Science, Changde 415000, China;
2. Changde Tobacco Machinery Compang Limited, Changde 415000, China;
3. Yichun Power Supply Branch, Jiangxi Province Power Company, State Grid, Yichun 336000, China)

Abstract: Considering the transient characteristics of short-circuit when fault occurred in power system transmission lines, the short-circuit currents are decomposed by applying LMD, and a series of PF components were obtained, then by calculating the 1 (1/2) dimension spectrum entropy of the fore 8 PF components among which as a feature vector which at last be put into the well trained Elman neural network to be realized fault recognition. A simulation model was established by Matlab, and the simulating results show that the method fast and accurately judge the fault type and fault phase, compared with the traditional BP network, the method has faster recognition speed, higher recognition rate, and also the recognition result is not influenced by the line parameters like transition resistance, fault location and phase angle etc. , so it is effective and practical.

Keywords: transmission line, fault recognition, LMD decomposition, 1 (1/2) dimension spectrum entropy, Elman neural network

当供电系统发生短路故障时,快速准确地识别出故障类型和故障相,有助于及时有效地切除故障,保证电力系统稳定运行. 当电力系统发生故障时,其故障暂态信号是非平稳随机信号,故障识别的关键是从故障暂态信号中提取出故障特征^[1-3]. 基于工频稳态量的传统识别方法因受发生故障点的距离、系统接地电阻及相邻输电线路的互感等因素影响,具有一定的局限性.

局部均值分解方法(LMD)是一种自适应性时频分析方法,非常适用于处理非线性、非平稳信号,尤其是多分量的调幅-调频信号^[4].1(1/2)维谱熵是一种三阶谱的简化算法,在军事、通信、机械故障诊断、振动分析等领域得到了广泛应用^[5],它既保留了双谱定量描述非线性相位耦合的特性,又弥补了双谱估计计算量大、精度不高的缺点^[6].1(1/2)维谱熵还能加强低频分量,有效提取信号中较弱的低频分量.而输电线路故障信号正是一种非线性、非平稳信号,因此可以利用LMD对故障信号进行分解,再利用1(1/2)维谱熵来度量故障信号的特征.

随着人工智能的发展,神经网络广泛应用于电力系统暂态保护、故障判断及选相,但是神经网络预测法存在网络结构难以确定、所需训练样本大、容易陷入局部极小值、收敛速度慢等缺点^[7-9].Elman神经网络是一种动态反馈网络,具有多输入多输出、学习速度快、全局最优、寻优精度高等特点,目前已在模式识别、负荷预测和故障诊断等领域得到广泛应用^[10-12].

本文提出了基于LMD-1(1/2)维谱熵-Elman神经网络的输电线路短路故障识别方法.当输电线路发生故障时,对采集到的三相故障电流进行相模变换,然后针对1模分量进行LMD分解,得到若干PF分量,选取前8个PF分量进行1(1/2)维谱熵特征向量提取,然后将特征向量作为Elman神经网络的输入进行模式识别.结果表明,该方法可以有效表征不同状态下线路故障信号的特性,快速准确地判别故障类型和故障相.

1 理论介绍

1.1 相模变换

由于三相输电线路的各相线之间有着相当复杂的电磁耦合关系,为了使计算更为简单有效,采用相模变换的方法来实现电磁解耦.本文采用一种新的相模变换方法-K变换^[13],该方法可以用单一的线模分量来表征所有的故障类型.以电流行波为例,K变换矩阵如下所示:

$$\begin{bmatrix} i_0 \\ i_1 \\ i_2 \end{bmatrix} = \begin{bmatrix} 1 & 1 & 1 \\ 1 & 2 & -3 \\ 1 & -3 & 2 \end{bmatrix} \begin{bmatrix} i_a \\ i_b \\ i_c \end{bmatrix}. \quad (1)$$

经K变换,三相系统分解出的3个变量 i_0, i_1, i_2 分别称为0模分量、1模分量和2模分量,本文对1模分量进行分析.

1.2 LMD

LMD是Smith提出的一种新的非线性和非平稳信号分析方法,采用滑动平均代替3次样条插值,通过自适应分解,获得一系列单分量调频调幅信号.

设分析信号为 $x(t)$,具体算法如下^[14]:

1) 确定原信号所有局部极值点(极大值点和极小值点) n_i ;

2) 通过步骤1),得局域均值 m_i 和包络估计值 a_i :

$$m_i = (n_i + n_{i+1})/2, \quad (2)$$

$$a_i = |n_i - n_{i+1}|/2. \quad (3)$$

3) 用滑动平均法对步骤2)所得的 m_i 和 a_i 进行平滑处理,得局部均值函数 $m_{11}(t)$ 和包络估计函数 $a_{11}(t)$;

4) 通过从原始信号 $x(t)$ 中分离出 $m_{11}(t)$,得到 $h_{11}(t) = x(t) - m_{11}(t)$,再用 $h_{11}(t)$ 除以 $a_{11}(t)$,得到 $s_{11}(t)$;

5) 若所得到的 $s_{11}(t)$ 并非一个在区间 $[-1, 1]$ 上的纯调频信号,可把 $s_{11}(t)$ 作为新的 $x(t)$,然后重复 n 次步骤1)到步骤4),直至所得到的 $s_{11}(t)$ 满足所要求;

6) 瞬时相位(Instantaneous Phase, IP)与瞬时频率(Instantaneous Frequency, IF)可由式(4)与式(5)分别得出:

$$\varphi_1(t) = \arccos(s_{11}(t)), \quad (4)$$

$$f_1(t) = \frac{d\varphi_1(t)}{2\pi dt}. \quad (5)$$

7) 将迭代过程中所产生的全部包络估计函数相乘,得包络信号(瞬时幅值函数):

$$a_1(t) = a_{11}(t)a_{12}(t)\cdots a_{1n}(t) = \prod_{q=1}^n a_{1q}(t). \quad (6)$$

从而首个乘积函数可由下式得到:

$$PF_1(t) = a_1(t)s_{1n}(t). \quad (7)$$

8) 将第一个 PF 分量 $PF_1(t)$ 从原始信号中分离出来,得到一个新的信号:

$$u_1(t) = x(t) - PF_1(t). \quad (8)$$

将其做为原始信号,重复上述步骤1)到步骤7) r 次,直到 $u_r(t)$ 为单调函数.此时,原信号就可表示为 r 个 PF 分量和一个单调分量的和:

$$x(t) = \sum_{p=1}^r PF_p(t) + u_r(t). \quad (9)$$

1.3 1(1/2)维谱

1) 定义

假设随机变量为 $x(t)$, 它的三阶自相关定义可以表示为

$$c(\tau_1, \tau_2) = E\{x(t)x(t+\tau_1)x(t+\tau_2)\}. \quad (10)$$

它的对角线切片表示为

$$c(\tau) = c(\tau, \tau) = E\{x(n)x(n+\tau)x(n+\tau)\}. \quad (11)$$

则 1(1/2) 维谱^[15]可以定义为对角线切片的 Fourier 变换

$$S(\omega) = \sum_{\tau=-\infty}^{+\infty} c(\tau) e^{-j\omega\tau} d\tau. \quad (12)$$

2) 计算方法

设观测数据为 $\{x_1, x_2, \dots, x_{N=rM}\}$ 共有 r 个记录, 每个记录包括 M 个数据, 则 1(1/2) 维谱的求法如下所示:

①对 r 个记录分别去均值;

②假定 $\{x^i(n), n = 0, 1, \dots, M-1\}$ 是第 i 个记录的数列, 那么求出:

$$C_{3x}^i(\tau) = \frac{1}{M} \sum_{n=s_1}^{s_2} x^i(n)x^i(n+\tau)x^i(n+\tau) \quad (i = 1, 2, \dots, r). \quad (13)$$

式中 $s_1 = \max(0, -\tau)$, $s_2 = \min(M-1, M-1-\tau)$;

③分别对 r 个记录的 $\hat{C}_{3x}^i(\tau)$ 求出它们的平均值, 表示为

$$\hat{C}_{3x}(\tau) = \frac{1}{r} \sum_{i=1}^r C_{3x}^i(\tau). \quad (14)$$

d) 对 $\hat{C}_{3x}(\tau)$ 作 FFT, 得到 $\hat{C}_{3x}(\tau)$ 谱.

3) 1(1/2) 维谱熵的特征提取方法

1(1/2) 维谱熵算法可以用于提取故障特征, 详细步骤如下所示:

①对初始信号 $S_r (r = 1, 2, \dots, N)$ 进行 LMD 分解处理, 提取出前 4 个 PF 分量 $S_{ji} (i = 0, 1, \dots, 2^j - 1)$ 在进行后续分析;

②对提取出来的 PF 分量依个进行 1(1/2) 维谱计算, 将会得到对应的 1(1/2) 维谱值 C_{ji} :

$$C_{j_i}(i = 0, 1, \dots, 2^J - 1). \quad (15)$$

③计算每个 PF 分量的 $1(1/2)$ 维谱值 E_{j_i} :

$$E_{j_i} = \sum_{r=1}^N |C_{j_i}(r)|. \quad (16)$$

④计算每个 PF 分量的 $1(1/2)$ 维谱熵 H_{j_i} :

$$H_{j_i} = \sum_{i=0}^{2^J-1} p_i \ln p_i. \quad (17)$$

式中, $p_i = E_i / \sum_{i=0}^{2^J-1} E_i$;

⑤将计算得到的 H_{j_i} 对白噪声序列的谱熵 $\ln N$ 进行归一化处理, $1(1/2)$ 维谱熵修正后表示为

$$H_{j_i}(f) = -100 \times \left(\sum_{i=1}^{2^J-1} p_i \ln p_i \right) / \ln N. \quad (18)$$

⑥由各 PF 分量维谱熵构成所需的特征向量 T :

$$T = [H_{j_0}, H_{j_1}, \dots, H_{j_l}] (l = 1, 2, \dots, 2^J - 1). \quad (19)$$

1.4 Elman 神经网络

Elman 神经网络是一种动态的反馈网络,亦可比作为一个前向神经网络^[16].它具有与多层前向网络相似的多层结构,其中含有输入层、隐含层、输出层,对于其连接权能够进行不断的学习修正;而它的反馈连接即是通过一组“结构”单元来进行构成的,它是用于进行记忆前一时刻的输出值,其中其连接权值固定不变.在 Elman 神经网络中,不仅含有普通的隐含层,它还有一个特别的隐含层,也即关联层,用于记忆隐层单元以前时刻的输出值.因此,Elman 神经网络可以高精度地逼近任意函数.

Elman 神经网络结构图如图 1 所示,设网络外部输入时间序列 $u(t)$, 反馈层输出 $y_c(t)$, 网络的输出 $y(t)$, 则 Elman 网络的数学模型为

$$\begin{cases} x_0(t+1) = {}^H W y_c(t+1) + {}^1 W u(t) + {}^1 \theta; \\ y_c(t) = o(t-1) = f_1(x_0(t-1)); \\ y(t) = f_2({}^2 W_0(t) + {}^2 \theta). \end{cases} \quad (20)$$

式中, f_1 和 f_2 是非线性作用函数; ${}^1 W$, ${}^H W$ 和 ${}^2 W$ 分别是输入层到隐层、反馈层到隐层和隐层到输出层的连接权矩阵.




图 1 Elman 神经网络结构图

2 基于 LMD-1(1/2) 维谱熵-Elman 神经网络输电线路短路故障识别流程

本文实验采用 SIMULINK/MATLAB 仿真数据来代替实测信号,基于 SIMULINK 搭建的仿真系统见图 3.其中,系统频率为 50 Hz,采样频率为 5 kHz.对采样的 1 模分量的故障电流信号进行 LMD 分解,然后对前 8 个 PF 分量进行 $1(1/2)$ 维谱熵特征提取,组成故障特征向量,然后将特征向量作为 Elman 神经网络的输入进行故障识别.

基于 LMD-1(1/2) 维谱熵-Elman 神经网络的输电线路短路故障识别流程图如图 2 所示.

3 仿真建模

采用图 3 所示的 500 kV 的双端系统仿真,选取线路参数: $Z_A = 0.0208 + j0.2821 \Omega/\text{km}$, $Z_B = 0.1148 + j0.7186 \Omega/\text{km}$, (j 为虚数符号), $C_1 = 0.0129 \mu\text{F}/\text{km}$, $C_0 = 0.0052 \mu\text{F}/\text{km}$, 线路总长度 500 km, 两端电源相角差依次选取为 20° , 30° , 60° 和 90° , 仿真时间 0.16 s, 其中故障持续时段为 0.06 s, 故障点位置距离电源 A 分别为 100 km, 200 km, 300 km, 和 400 km, 短路过渡电阻取 10Ω , 40Ω , 70Ω 和 100Ω 时, 对应的

10种故障和正常状态共产生样本1320个.

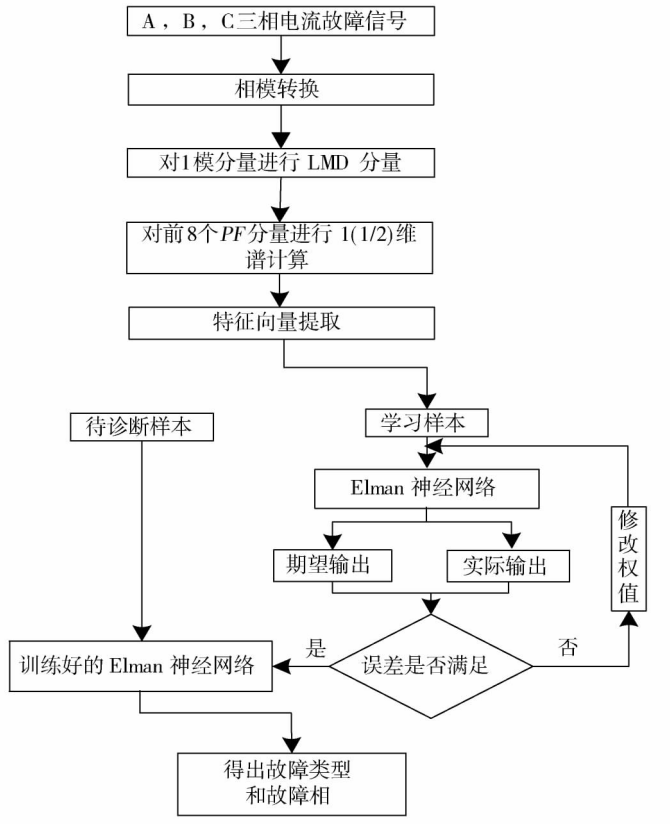


图2 故障识别流程图

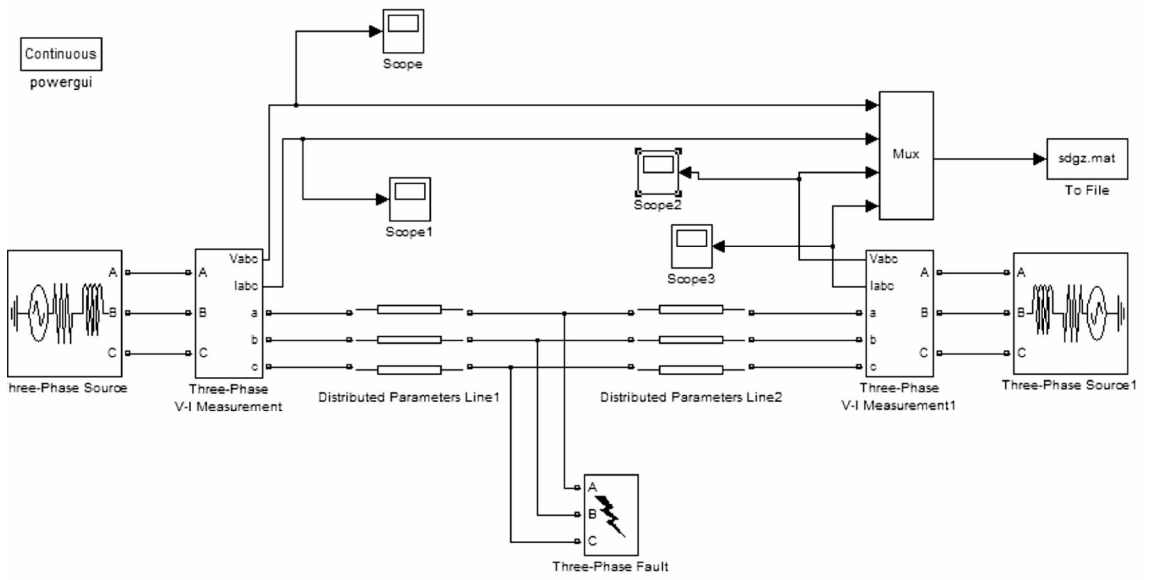


图3 电力系统输电线路仿真图

4 故障特征的提取

4.1 故障电流 LMD 分解

在建立的输电线路故障仿真模型中,设置各种故障类型,得到故障电流的波形,以 ABC 故障类型为例,如图 4 所示. 然后对故障信号进行相模变换,对所得到的 1 模分量进行 LMD 分解,得到若干 PF 分量,根据 LMD 分解的特点,一般前几个 PF 分量可以表征原始信号,因此统一选取 $PF_1 \sim PF_8$ 作为进一步特征

提取的对象.图 5 表示 ABC 故障下故障电流的 LMD 分解效果.

4.2 1(1/2)维谱熵计算

在对故障电流信号进行 LMD 分解之后,在得到的一系列 PF 分量中选取前 8 个 PF 分量,对其进行 1(1/2)维谱计算,进而得出各分量的维谱熵值.

从图 6 中可得不同故障类型的故障特征为

- 1) 不同的故障类型,其对应的各 PF 分量的 1(1/2)维谱熵值明显不同;
- 2) 非接地故障信号各分量的 1(1/2)维谱熵值明显大于接地故障信号各分量的 1(1/2)维谱熵值;




图 4 ABC 故障下电流波形




图 5 ABC 故障下电流 LMD 分量

- 3) 故障信号各分量的 1(1/2)维谱熵值随着分解阶数的增加呈减少的趋势,符合 LMD 分解的原理.

为了测试该识别方法是否会随着线路的参数改变而发生错误识别情况,对不同故障点、不同过渡电阻和不同相角时的各故障信号进行反复试验,计算故障信号的 1(1/2)维谱熵值变化情况.图 7 为 ABC 故障下改变线路参数时故障特征量的对比效果.




图 6 不同故障类型的故障特征




图 7 ABC 故障下不同线路参数的故障特征

由图 7 可知,ABC 故障下,改变线路参数(故障点、相差角、过渡电阻)时,其故障特征值的变化趋势一致,且幅值变化很小,分布区间狭窄恒定.由此可以判定,改变线路参数不会造成对 ABC 故障识别的错误

判断.

同样,通过改变线路参数,我们得到涉及 A 相的 4 种短路故障(ABC, AB, ABg, Ag)下的故障信号特征对比效果,如图 8 所示.




图 8 4 种故障类型故障特征对比

为了更直观、更形象的显示出当改变线路参数时,采用 $1(1/2)$ 维谱熵值来表征故障类型是不会受到影响而出现错误识别现象.以初始线路参数($R_l = 10 \Omega, L = 100 \text{ km}, \theta = 20^\circ$)发生短路故障时的特征值作为基准值.用改变各线路参数发生短路时的故障特征值与基准值进行差计算,计算结果如图 9 所示.

由上述得知:对于同一种故障类型,随着线路参数的改变,其各分量的 $1(1/2)$ 维谱熵值变化规律基本相同,说明这种特征基本不受过渡电阻、故障点、相角差的影响;不同故障类型故障的 $1(1/2)$ 维谱熵值分布区间各自不同,不同线路参数的 $1(1/2)$ 维谱熵值差值非常小,最大差值都小于 0.1,趋势也基本一致,改变不同的线路参数对 $1(1/2)$ 熵值的分布不会造成影响,不会因为线路参数的变化而引发故障类型混叠,无法判断的现象.

因此,利用 $LMD - 1(1/2)$ 维谱熵值作为故障特征是可行的.虽然 $1(1/2)$ 维谱熵值能表征不同的故障特征,但是仅从熵值的大小区分和判别故障类型是不够的,不仅繁琐,而且由于数据的庞大,极容易出现错误判断,因此需要将其与分类器相结合才能有效地进行识别.

5 Elman 神经网络故障识别

将计算所得的各 PF 维谱熵值作为 Elman 神经网络的输入,记为 $E = (E_1, E_2, E_3, E_4, E_5, E_6, E_7, E_8)$,然后进行故障类型的识别.首先将经过计算各故障类型大量的特征值作为训练样本输入,对神经网络进行训练,然后设定好各参数,待神经网络完成训练后,输入测试样本进行测试.各故障类型的测试结果由图 10 和图 11 所示.

图 13 为 ABC 故障识别的迭代过程.将逼近误差率设定为 10^{-2} ,当迭代次数约为 170 时,测试向量开始收敛,到 226 次时,完全收敛,完成识别过程,识别网络停止迭代,分析并给出识别效果.

当迭代次数为 226 次,停止迭代,完成故障类型识别,由图 11 可以知道:ABC 故障识别的误差值为 0.004 021 1,识别正确率为 99.7%,识别时间为 2 s,错误次数为 0 次.由识别结果可知,ABC 故障的识别结果明显、识别效果非常好.因此对于 ABC 故障的识别,用本文的特征向量提取与 Elman 神经网络结合的方法是可行的.




图 9 不同故障类型故障不同线路参数特征值最大误差




图 10 ABC 故障识别的迭代次数

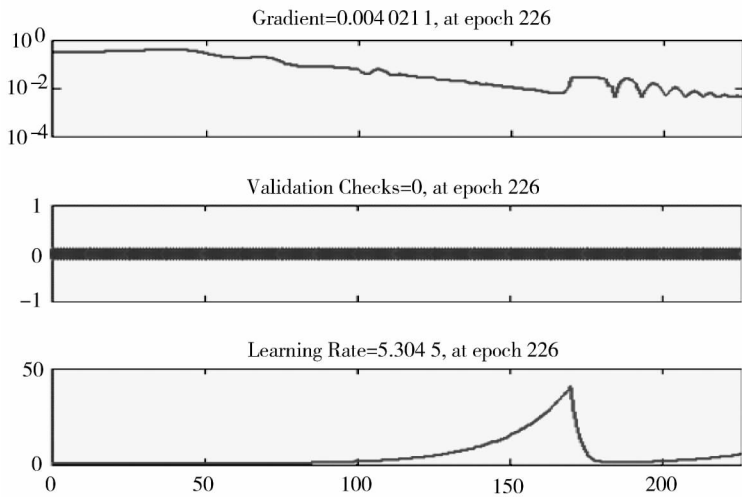


图 11 ABC 故障的识别效果

6 结果与分析

利用仿真实验所得到的各类故障数据对本文所提出的输电线路短路故障识别方法进行测试,同时为了验证该方法的可行性与更优性,与 BP 神经网络识别方法所进行的比较分析,对比结果记录如表 1、表 2 所示. 根据表 1 可知:基于 BP 神经网络识别方法的故障识别的正确率平均为 90.15%;而本文所提出的故障识别新方法效果更佳,故障识别的正确率平均可达到 97.95%. 这是由于 BP 神经网络具有网络结构难以确定、容易陷入局部极小值和收敛速度慢等缺点. 表 2 给出了 BP 神经网络与 Elman 神经网络的识别速度对比,显而易见,本文所采用的 Elman 神经网络的识别速度更快. 由此可以看出基于 LMD-1(1/2)维谱熵-Elman 神经网络的输电线路故障识别方法是可行的,并且具有更好的故障识别效果.

表 1 识别率对比

故障类型	样本数	BP 神经网络误判数	BP 神经网络识别率/%	Elman 神经网络误判数	Elman 神经网络识别率/%
Ag Fault	132	16	87.90	4	96.80
Bg Fault	132	17	87.10	3	97.60
Cg Fault	132	10	92.40	5	96.00
ABg Fault	132	13	90.10	2	98.40
BCg Fault	132	11	91.70	1	99.20
CAG Fault	132	15	88.60	1	99.20
AB Fault	132	12	90.90	2	98.40
BC Fault	132	10	92.40	1	99.20
CA Fault	132	14	89.40	4	96.80
ABC Fault	132	12	90.90	4	96.80
总计	1 320	130	90.15	27	97.95

表2 识别速度对比

故障类型	样本数	BP神经网络平均识别时间/s	Elman神经网络平均识别时间/s
Ag Fault	132	5.6	2.3
Bg Fault	132	7.4	3.1
Cg Fault	132	4.7	2.4
ABg Fault	132	6.6	3.1
BCg Fault	132	4.2	2.6
CAG Fault	132	6.3	2.9
AB Fault	132	5.1	2.6
BC Fault	132	4.8	3.3
CA Fault	132	6.8	2.7
ABC Fault	132	5.6	2.1

7 结论

本文提出了一种基于LMD-1(1/2)维谱熵-Elman神经网络的识别方法,并将该方法运用于输电线路故障类型识别之中.通过建立仿真模型进行该识别方法进行验证,实验结果表明本文所运用的方法能有效地判断出输电线路短路故障类型与故障相,并且对比传统识别方法,该方法不仅识别速度快、识别率高,且不受线路参数的影响.

参考文献:

- [1] 齐郑,乔丰,黄哲洙,等.基于暂态分量遗传算法的小电流接地故障定位方法[J].电力系统保护与控制,2014,42(1):1-3.
- [2] 董明,张勇,张岩,等.含电气量信息的电力系统故障诊断解析模型[J].电力系统自动化,2013,37(6):1-5.
- [3] 廖志伟,岳苓,文福栓,等.基于混合规则网络和警报时序特性电力系统故障诊断[J].电力系统自动化,2013,37(10):2-6.
- [4] 黄传金,曹文思,陈铁军,等.局部均值分解在电力系统间谐波和谐波失真信号检测中的应用[J].电力自动化设备,2013,33(9):3-8.
- [5] 吴正国,夏立,尹为民.现代信号处理技术:高阶谱、时频分析与小波变换[M].武汉:武汉大学出版社,2003.
- [6] Giannakis G B, Mendel J M. Identification of non-minimum phase systems using higher-order statistics[J]. IEEE Trans. Acoustics, Speech, Signal Processing, 1989,16(37):360-377.
- [7] Mao P L, Aggarwal R K. A novel approach to the classification of the transient phenomena in power transformers using combined wavelet transform and network[J]. IEEE Transactions on Power Delivery, 2001,16(4):654-660.
- [8] Silva K M, Souza B A, Brito N S D. Fault detection and classification in transmission lines on wavelet transform and ANN[J]. IEEE Transactions on Power Delivery, 2006,21(4):2058-2063.
- [9] Mahanty R N, Gupta P B D. Application of RBF neural network to fault classification and location in transmission lines[J]. Proc Inst Elect Eng, 2004,151(2):201-212.
- [10] 王强,周云龙,乘思勇,等.基于小波和Elman神经网络的气液两相流型识别方法[J].热能动力工程,2007,22(2):169-171.
- [11] 杨嘉,吴祥生,王宁,等.基于Elman型神经网络的空调负荷预测模型[J].重庆大学学报(自然科学版),2002,25(8):25-27.
- [12] 陈法法,汤宝平,黄庆卿.免疫遗传优化Elman神经网络的旋转机械故障诊断[J].重庆大学学报,2012,35(5):8-10.
- [13] 宋国冰,李森,康小宁,等.一种新相模变换矩阵[J].电力系统自动化,2007,31(14):57-60.
- [14] 程军圣,杨宇,于德介.局部均值分解方法及其在齿轮故障诊断中的应用[J].振动工程学报,2009,22(1):76-84.
- [15] 严可国,柳亦兵,徐鸿,等.基于双谱分析的大型汽轮机振动故障特性提取[J].中国电机工程学报,2010,30(2):4-8.
- [16] 刘建华,李天玉,付娟娟,等.基于BP和Elman神经网络的智能变电站录波启动判据算法[J].电力系统保护与控制,2014,42(5):2-5.