

文章编号:1005-0523(2014)03-0088-07

基于形态学分形维数的输电线路故障选相方法

宋平岗,周 军,蔡 双

(华东交通大学电气与电子工程学院,江西 南昌 330013)

摘要:输电线路故障信号是一种典型的非线性信号,分形几何理论为描述非线性故障信号的特性提供了一个有力的分析工具。针对传统分形维数的局限性,本文提出了一种基于局域均值分解(local mean decomposition, LMD)-形态学的分形维数-Elman神经网络的输电线路故障选相新方法。该方法通过对故障电流进行相模转换后,对单一线模分量进行LMD分解得到若干乘积函数(product function, PF)分量,然后选取前4个PF分量进行数学形态学的分形维数估计,最后形成特征向量作为Elman神经网络的输入参数。仿真试验表明:提出的故障分类识别方法能快速、准确地识别各类故障,并且不易受故障初始角、故障位置和过渡电阻的影响,与传统的BP神经网络相比,Elman神经网络具有更好的效果,为准确判断输电线路故障选相提供了一种快速有效的新方法。

关键词:LMD;数学形态学;分形维数;Elman神经网络;输电线路;故障分类

中图分类号:TM711

文献标志码:A

当电力系统发生故障的时候,如何迅速、准确地选出故障类型对于继电保护装置正确动作和切除故障都具有十分重要的意义。然而传统的故障类型识别方法一般是基于工频稳态量,此类方法容易受接地电阻、故障点的距离以及初始相角差等因素的影响^[1],系统发生故障所产生的暂态信号是一非平稳随机过程^[2],如何从非平稳信号中提取出故障特征是关键。

EMD是一种新的自适应时频分析方法,其基函数在分解过程中自动产生,分解出IMF分量中的频率是随信号变化而变化,适合短路故障信号的特征提取。EMD在线路故障诊断领域已经有了一些应用^[3-4]。但仍存在一些缺陷,如虚假分量、模式混淆等问题^[5]。LMD是Smith.JS提出的一种自适应分解方法,可以将非平稳信号自适应地分解成若干个PF分量之和,每个分量均为其包络信号和纯调频信号的积^[6]。相比EMD的IMF分量而言,具有可以保存更多的频率和包络信息、迭代次数少、运算速度快和端点效应不明显等优势。分形几何为复杂信号提供了一种几何结构分析方法,在很多领域已经有了成功的应用。在输电线路故障诊断领域中,人们也开始用分形几何方法对故障信号进行分析,并取得了一定的成果^[7-8]。分形维数是度量分形的重要指标,有许多分形维数可用来刻画信号的复杂度,其中盒维数最常见,其缺点是分形维数估计不准确^[9]。

P.Maragos将数学形态学引入了分形维数的计算方法当中,提出了一种通过形态滤波算法来估计信号的分形维数的新方法^[10]。相比盒维数计算,由于其采用了一维信号的处理方法,而且不受信号旋转平移和幅值范围等各种因素的制约,其估计更加精确。目前,数学形态学的分形维数估计方法已经在图像分割、声信号处理、医学信号处理等领域得到应用^[11-13],但在输电线路故障信号识别方面的应用还未见报道。

本文提出了基于LMD-形态学的分形维数-Elman神经网络的线路故障分类方法,当输电线路发生故

收稿日期:2013-07-30

作者简介:宋平岗(1965—),男,教授,博士,主要研究方向是电力牵引与传动控制电力电子技术及其应用和再生能源系统。

障时,采集三相电流进行相模变换,得到变换后的各模量,然后对单一线模分量进行LMD分解,得到若干PF分量,选取前4个PF进行形态学的分形维数估计,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,很好的区分了故障类型,故障诊断率高。

1 理论介绍

1.1 相模变换

三相输电线路的各相线之间存在复杂的电磁耦合关系,为了简化计算,一般采用相模变换实现解耦。本文选用了一种新的相模变换方法——K变换^[14],该变换可用单一线模分量反应所有的故障类型,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原理

LMD是由Smith提出的一种新的非线性和非平稳信号分析方法。与EMD不同的是其采用滑动平均代替3次样条插值,通过自适应分解,可获得一系列单分量的调频调幅信号。

设分析信号为 $x(t)$,其具体算法如下^[15]:

1) 确定原信号所有的局部极值点(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 $m_{11}(t)$,可得到 $h_{11}(t) = x(t) - m_{11}(t)$ 。再用 $h_{11}(t)$ 除以 $a_{11}(t)$,得到 $s_{11}(t) = h_{11}(t)/a_{11}(t)$ 。

5) 若所得到的 $s_{11}(t)$ 并非是一个在区间 $[-1, 1]$ 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) k 次,直到 $u_k(t)$ 为单调函数。此时,原信号就可表示为 k 个

PF 分量和一个单调分量的和:

$$x(t) = \sum_{p=1}^k PF_p(t) + u_k(t) \quad (9)$$

1.3 数学形态学

1.3.1 数学形态学的基本原理

法国数学家 G.Matheron 和 J.Sarra 等人在上世纪 80 年代初创立了形态滤波理论^[16], 面对处理对象的形状特征的不同, 通过采用某种特定的结构元素进行不断的形态变换, 以此达到处理信号的目的。

假设 $f(n)$ 和 $g(n)$ 分别为定义在离散域 $F = \{0, 1, \dots, N-1\}$ 和 $G = \{0, 1, \dots, M-1\}$ 的实函数, 其中 $f(n)$ 为原始输入信号, $g(n)$ 为结构元素, $N > M$ 。那么 $f(n)$ 关于 $g(n)$ 的 4 种基本运算: 腐蚀运算 ($\ominus$)、膨胀运算 ($\oplus$)、开运算 ($\circ$) 和闭运算 ($\cdot$) 分别为

$$(f \ominus g)(n) = \min[f(n+m) - g(m)], \quad m \in 0, 1, \dots, M-1 \quad (10)$$

$$(f \oplus g)(n) = \max[f(n-m) + g(m)], \quad m \in 0, 1, \dots, M-1 \quad (11)$$

$$(f \circ g) = (f \ominus g \oplus g)(n) \quad (12)$$

$$(f \cdot g) = (f \oplus g \ominus g)(n) \quad (13)$$

1.3.2 多尺度形态学定义

多尺度运算的思想是采用不同尺度的结构元素而进行的形态变换, 通过不同尺度的结构元素对信号进行处理, 它与感知机制相匹配的这种多层次特点是其一大优势^[11], 假设对 $f(x)$ 的形态运算为 $F(f)$, 那么可以定义多尺度形态运算为

$$F_\lambda(f) = \lambda[F(f_\lambda(x)/\lambda)]_{1/\lambda} \quad (14)$$

其中, $\lambda (\lambda > 0)$ 为 $F_\lambda(f)$ 的尺度, 由式 (14) 推出腐蚀运算、膨胀运算、开运算和闭运算的多尺度运算分别为

$$(f \ominus g)_\lambda = f \ominus \lambda g_{1/\lambda} \quad (15)$$

$$(f \oplus g)_\lambda = f \oplus \lambda g_{1/\lambda} \quad (16)$$

$$(f \circ g)_\lambda = f \circ \lambda g_{1/\lambda} \quad (17)$$

$$(f \cdot g)_\lambda = f \cdot \lambda g_{1/\lambda} \quad (18)$$

式中: $g_{1/\lambda} = g(x/\lambda)$ 。由上述公式可看出, 多尺度运算只需用 $\lambda g_{1/\lambda}$ 更换结构元素 g 。若取结构元素为凸函数时, 随着尺度 λ 的增大, 多尺度运算会滤去信号更大的变化, 使信号的形态越来越简单。

1.3.3 数学形态学的分形维数

定义尺度 λ 对信号的覆盖面积为

$$S_g(\lambda) = \sum_{n=1}^N [(f \oplus g)_\lambda - (f \ominus g)_\lambda] \quad (19)$$

$S_g(\lambda)$ 满足如下条件:

$$\log(S_g(\lambda)/\lambda^2) = D_\lambda \log(1/\lambda) + c, \quad \lambda = 1, 2, \dots, \lambda_{\max} \quad (20)$$

式中: D_λ 为信号在尺度 λ 下的 Minkowski-Bouligand 维数; c 为常数; $\lambda_{\max}$ 为分析信号的最大尺度。因此, 对 $\log(S_g(\lambda)/\lambda^2)$ 和 $\log(1/\lambda)$ 进行最小二乘线性拟合即可得到信号在对应尺度 λ 下的 Minkowski-Bouligand 维数的估计。

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^[9]。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, 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, 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

$$\left. \begin{aligned} x_0(t+1) &= {}^uW y_c(t+1) + {}^1W u(t) + {}^1\theta \\ y_c(t) &= o(t-1) = f_1(x_0(t-1)) \\ y(t) &= f_2({}^2W_0(t) + {}^2\theta) \end{aligned} \right\} \quad (21)$$

式中: f_1 和 f_2 是非线性作用函数; 1W , uW 和 2W 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重矩阵。




图1 Elman神经网络结构图

Fig. 1 Elman neural network structure

2 基于形态学广义分形维数-Elman神经网络的输电线路故障类型识别方法

实验采用SIMULINK/MATLAB仿真数据代替实测信号,基于SIMULINK搭建的仿真系统见图2。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4个PF分量进行形态学分形维数估计,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模式识别。

基于LMD-形态学分形维数-Elman神经网络的电力系统故障分类流程图如图3所示。




图2 系统仿真模型

Fig.2 System simulation model




图3 故障分类流程图

Fig.3 Fault classification flowchart

3 实验分析

3.1 实验数据

采用图2所示的500 kV的双端系统仿真,选 $Z_A=0.020\ 8+j0.282\ 1\ \Omega\cdot\text{km}^{-1}$, $Z_B=0.114\ 8+j0.718\ 6\ \Omega\cdot\text{km}^{-1}$, $C_1=0.012\ 9\ \mu\text{F}\cdot\text{km}^{-1}$, $C_0=0.005\ 2\ \mu\text{F}\cdot\text{km}^{-1}$,线路总长度300 km,两段电源相角差分别取20°,30°,50°,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, 120, 150 km, 180 m和200 km, 短路过渡电阻取20, 40, 60, 80 Ω 和100 Ω 时, 对应的10种故障和正常状态共产生样本1 250个。

3.2 特征向量的选取

首先对1模分量进行LMD分解, 发现信号分解出的PF个数为5~11个不等, 根据LMD的特点, 一般前几个PF包含了原始信号的绝大多数信息, 而最后几个分量对分析意义不大, 因此统一选取PF 1~PF5作为进一步特征提取的对象。然后对前4个PF进行形态学分形维数估计, 进而求出各分量的分形维数估计值, 将各PF的形态学分形维数估计值作为Elman神经网络的输入, 记为 $E=(E_1, E_2, E_3, E_4)$, 然后进行故障类型的识别。

从图4可得, 不同故障类型的故障特征为

1) 不同的故障类型对应的各PF分量的形态学分形维数估计值明显不同。

2) 非接地故障的分形维数估计值相对大些; 而接地故障时, 各分量的估计值相对小些。

3) 各分量的分形维数估计值随着分解阶数的增加呈减少的趋势, 也即是各分量越来越规则了, 这符合LMD分解的原理。

为了测试该诊断模型是否会随着线路的一些参数改变而发生误诊, 对不同故障点、不同过渡电阻和不同相角差的故障信号进行反复试验, 图5描述了在同一故障类型Ag的情况下, 通过改变故障点、过渡电阻和相角差来, 测试其对应的各形态学的分形维数变化情况。




图4 不同故障类型的故障特征柱状图

Fig. 4 Histogram of fault characteristics of different fault types




图5 Ag状态下的特征柱状图

Fig. 5 The histogram of characteristics under Ag state

从图5可以看出, 对于同一种故障类型, 随着线路参数的改变, 其各分量的数学形态学分形维数估计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。同时, 图6为Ag故障状态下, 不同工况(不同过渡电阻、不同故障点、不同相角差)之间的测试误差曲线。从图中可以看出, 其相对误差值很小, 基本都小于0.1, 因此, 利用LMD-数学形态学分形维数估计值作为故障特征是可行的, 虽然分形维数估计值能反映不同的故障特征, 但是仅从估计值的大小区分和判别故障类型是不够的, 将其与分类器相结合才能有效地分类。

3.3 故障诊断试验结果与分析

根据故障特征的特点建立网络的训练样本, 因为线路的故障有4个征兆数, 可分为10大类运行状态, 因此输入层神经元的个数为4; 输出层神经元的个数为10; 综合考虑网络的性能和速度, 将隐含层神经元的

个数设定为40,即网络具有4-40-10的结构,结构层亦为40个节点,网络的初始权值在 $[-1,1]$ 之间随机选取,固定增益 a 为0.9,学习速率 η 为0.01。测试结果如表1所示。

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故障选相方法进行测试,同时为了验证该方法的可行性,与BP神经网络识别方法所进行的比较分析,其中,采用BP神经网络识别方法获得诊断结果如表1所示。根据表1可知:基于BP神经网络识别方法的故障分类正确率平均为92.4%;而本文所提出的故障选相新方法效果更佳,故障分类的正确率平均可达到98.6%。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。由此可以看出LMD-形态学的分形维数-Elman神经网络具有较强的故障诊断能力。

表1 测试结果

Tab.1 Test results

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	125	13	89.6	2	98.4
Bg Fault	125	14	88.8	3	97.6
Cg Fault	125	8	93.6	1	99.2
ABg Fault	125	11	91.2	0	100.0
BCg Fault	125	6	95.2	1	99.2
CAG Fault	125	9	92.8	1	99.2
AB Fault	125	11	91.2	3	97.6
BC Fault	125	5	96.0	4	96.8
CA Fault	125	6	95.2	2	98.4
ABC Fault	125	12	90.4	0	100.0
总计	1 250	95	92.4	17	98.64

4 结论

将LMD-形态学分形维数-Elman神经网络的方法运用于输电线路故障类型识别之中,当输电线路发生故障时,采集三相电流进行相模变换,计算出变换后的各模量,然后对单一线模分量经LMD分解得到若干 PF 分量,再对前4个 PF 分量进行形态学的分形维数估计,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模式识别。实验结果表明本文方法能够对输电线路运行状态有效识别,与BP神经网络方法相比较,具有收敛速度快,诊断识别率高的优点,证实了本文方法的可行性。

参考文献:

- [1] 段建东,张保会,周艺,等.基于暂态量的超高压输电线路故障选相[J].中国电机工程学报,2006,26(3):1-6.
- [2] 祝志慧,孙云莲.基于EMD近似熵和SVM的电力线路故障类型识别[J].电力自动化设备,2008,28(7):81-84.
- [3] 李云丰,宋平岗,王丽娜,等.一种模块化多电平换流器数学模型的建立方法[J].华东交通大学学报,2013,30(2):37-41.




图6 误差曲线图

Fig. 6 Error curve

- [4] 李晓晨,陈昌雷.基于EMD奇异值熵的高压输电线路故障选相新方法[J].中国电力,2011,44(5):6-9.
- [5] 郝如江,卢文秀,褚福磊.滚动轴承故障信号的多尺度形态学分析[J].机械工程学报,2008,44(11):160-165.
- [6] SMITH S J. The local mean decomposition and its application to EEG perception data [J].Journal of the Royal Society Interface, 2005,2(5):443-454.
- [7] 孙文涛,许文杰,云雷,等.基于分形盒维数的输电线路故障识别研究[J].陕西电力,2012(2):1-3.
- [8] 孙雅明,王俊丰.基于分形理论的输电线路故障类型识别新方法[J].电力系统自动化,2005,29(12):23-28.
- [9] CHAUDHURI B B,SAKAR N.Texture segmentation using fractal dimension [J].IEEE Transactions on Pattern Analysis and Machine Intelligence, 1995,17(1):72-77.
- [10] MARAGOS P,SUN F K.Measuring the fractal dimension of signals: morphological covers and iterative optimization [J].IEEE Transactions on Signal Processing,1993,41(1):108-121.
- [11] XIA Y,FENG D,ZHAO R.Morphology-based multifractal estimation for texture segmentation [J].IEEE Transactions on Image Processing,2006,15(3):614-623.
- [12] MARAGOS P,POTAMIANOS A.Fractal dimensions of speech sounds: computation and application to automatic speech recognition [J].Journal of the Acoustical Society of America,1999,105(3):1925-1932.
- [13] ACCARDO A,AFFINITO M,CARROZZI M,et al.Use of the fractal dimension for the analysis of electroencephalographic time series [J].Biological Cybernetics,1997,77(5):339-350.
- [14] 宋国冰,李森,康小宁,等.一种新的相模变换矩阵[J].电力系统自动化,2007,31(14):57-60.
- [15] 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.
- [16] 郝如江,卢文秀,褚福磊.滚动轴承故障信号的数学形态学提取方法[J].中国电机工程学报,2008,28(26):65-70.
- [17] 张雷,赵明扬,王立柱,等.基于数学形态学的激光拼焊熔池图像处理研究[J].仪器仪表学报,2007,28(9):1668-1672.
- [18] 汤宝平,习建民,李锋.基于Elman神经网络的旋转机械故障诊断[J].计算机集成制造系统,2010,16(10):2148-2152.

Faulty Phase Identification of Transmission Lines Based on Morphology Fractal Dimensions

Song Pinggang, Zhou Jun, Cai Shuang

(School of Electrical and Electronic Engineering, East China Jiaotong University, Nanchang 330013, China)

Abstract: The fault signal of transmission lines is typically nonlinear, and the fractal geometrical theory provides an efficient tool to describe its features. In order to overcome the deficiency of the traditional calculation method of the fractal dimensions, this paper presents a new method for faulty phase identification of transmission lines based on local mean decomposition (LMD)-morphology fractal dimensions-Elman neural network. Firstly, it decomposes single line mode component into some product function (PF) by LMD after the phase-to-analog conversion of the fault current; Then it calculates the morphology fractal dimensions value by the first four PF s; Finally, it inputs the value into the Elman neural network as a new eigenvector to characterize the fault type. Simulation results show that this method can effectively extract the fault types and is also insensitive to different fault initial angles, distances and resistances. Moreover, compared with BP network, Elman neural network has better results. Thus the proposed method was verified as a fast and effective technique for the accurate identification of faulty phase of transmission lines.

Key words: LMD; mathematical morphology; fractal dimensions; Elman neural network; power transmission line; fault type classification