

文章编号:1672-9331(2018)03-0085-09

基于 ILMD 和神经网络的电压扰动识别分类

王旭红, 杨思阳, 李 良

(长沙理工大学 电气与信息工程学院, 湖南 长沙 410114)

摘要: 为了识别电力系统存在的扰动信号,减少扰动信号对系统安全的影响,提出了一种改进局部均值分解法(Improved Local Mean Decomposition,简称 ILMD)与 BP 神经网络相结合的电压扰动信号分类器对电压扰动进行识别分类。通过 ILMD 对电压扰动信号进行 3 层分解,得到包含电压原始信号频率、幅值的乘积分量(Product Function,简称 PF),将 PF 分量构建的信号能量值作为 BP 神经网络的输入,实现对电压扰动信号的识别分类。通过对系统中 4 种典型电压扰动信号进行识别试验,结果表明,基于 LMD 和神经网络的电压信号分类器准确度高,并具有较高的工作效率。

关键词: 扰动信号;局部均值分解;端点延拓;信号分解;BP 神经网络;信号分类

中图分类号:TM935

文献标识码:A

Voltage disturbance signals identification based on improved LMD and neural network

WANG Xu-hong, YANG Si-yang, LI Liang

(School of Electrical and Information Engineering, Changsha University of Science and Technology, Changsha 410114, China)

Abstract: In order to identify the disturbance signal in the power system and reduce the influence of disturbance signal on system security, a voltage disturbance signal classifier based on improved local mean decomposition and BP neural network is proposed. Disturbance signals are decomposed in three layers by LMD, obtaining product function components with amplitude and frequency information of the voltage signal. The signal energy value constructed by the PF components is as an input of the BP neural network to identify and classify the voltage disturbance signal. Experiments on the four typical voltage disturbance signals show that the signal classifier based on LMD and BP neural network has high accuracy and good working efficiency in voltage disturbance signals recognition and classification.

Key words: disturbing signal; LMD; endpoint extension; signal decomposition; BP neural network; signal classification

电力系统在运行过程中,存在大量非线性、不规则的电力信号。同时,受到各种故障、开关闭合

操作、雷击等情况的影响,会产生大量的扰动信号,这些信号的存在使电力系统电压幅值、频率产

收稿日期:2018-04-10

基金项目:国家自然科学基金资助项目(61473049)

通讯作者:王旭红(1969-),女,湖南长沙人,长沙理工大学教授,博士,主要从事电力设备状态在线监测与故障诊断方面的研究。E-mail:348877201@qq.com

生畸变,影响电力设备的正常运行,进而影响电力系统的安全^[1]。因此,对电力系统中存在的电压暂态扰动信号进行分析与分类,对电力系统故障诊断和暂态保护以及维护系统安全运行有重要的意义^[2,3]。

目前,针对电压扰动信号处理的方法种类很多,但在对非线性信号和非平稳信号的处理中,都存在一定的缺陷。傅里叶变换是传统的信号提取与处理方法,但它不适用于处理非线性和非平稳信号,并存在频谱泄露和栅栏现象^[4];小波及小波包变换不属于真正的自适应变换,必须在构造严格的标准函数的基础上进行信号的分解,否则无法达到最佳的分解效果^[5,6];S变换是加窗傅立叶变换和连续小波变换思想的结合与推广,该变换窗函数是一个随频率变化而伸缩的高斯函数,因此受到噪音的影响较大^[7];HHT法和EMD法容易受到过包络和欠包络现象的影响,存在较严重的端点污染,使得检测出现无法解释的数值^[8]。

局部均值分解(Local Mean Decomposition,简称LMD)是一种新的自适应信号分解方法,可以将复杂扰动信号分解为若干个瞬时频率具有物理意义的乘积函数(Product Function,简称PF),揭示扰动信号的本质信息,反映信号的扰动程度^[9]。在分解过程中不需要将分解量重复使用,故LMD法的效率和分解速度明显快于HHT法和EMD法。在对暂态扰动信号的时间、频率等项目的检测中,精度较高,端点效应的影响远小于HHT法和EMD法,是一种可用于暂态扰动信号检测的新方法。神经网络是基于人类大脑功能和结构而建立起的信息处理系统,具有信息学习、分类的能力^[10]。因此,作者将LMD法与BP神经网络相结合,构成电压扰动信号分类器,实现对电压扰动信号进行快速、准确地分类。

1 局部均值分解法

1.1 局部均值分解原理

局部均值分解法对信号的分解步骤如下。

- 1) 求得初始电压信号 $u(t)$ 中所有局部极值点 m_i 。
- 2) 计算任意两个相邻局部极值点的平均值

$n_i = 1/2(m_i + m_{i+1})$ 和幅值包络估计值 $a_i = 1/2|m_i + m_{i+1}|$, 局部均值函数 $n_{11}(t)$ 和幅值包络估计函数 $a_{11}(t)$ 。

3) 从原始信号 $u(t)$ 中分离出局部均值函数, $n_{11}(t)$ 获得信号 $h_{11}(t)$ 。

4) 获得调频信号: $s_{11}(t) = h_{11}(t)/a_{11}(t)$ 。

5) 判断 $s_{11}(t)$ 是否为纯调频信号, 对得到的调频信号重复上述步骤, 得到关于 $s_{11}(t)$ 的幅值包络估计函数 $a_{1n}(t)$ 。当 $a_{1n}(t) = 1$ 时, 说明该信号是纯调频信号; 反之, 则不是纯调频信号, 需重复迭代。迭代过程为:

$$\begin{cases} h_{11}(t) = x(t) - n_{11}(t) \\ h_{12}(t) = s_{11}(t) - n_{12}(t) \\ \vdots \\ h_{1n}(t) = s_{1(n-1)}(t) - n_{1n}(t) \end{cases} \quad (1)$$

式中: $s_{1n}(t) = \frac{h_{1n}(t)}{a_{1n}(t)}$ 。

式(1)的迭代终止条件为: $\lim_{n \rightarrow \infty} a_{1n}(t) = 1$ 。

6) 将迭代过程得到的包络估计函数相乘, 得到幅值包络信号 $a_1(t)$:

$$a_1(t) = a_{11}(t)a_{12}(t)\cdots a_{1n}(t) = \prod_{k=1}^n a_{1k}(t) \quad (2)$$

7) 包络信号 $a_1(t)$ 与纯调频信号 $s_{1n}(t)$ 乘积获得原始信号 $u(t)$ 的第一个乘积函数分量: $PF_1 = a_1(t)s_{1n}(t)$ 。该 PF 函数分量包含原始信号中最高频率信号的所有瞬间幅值和频率。

8) 原始信号 $u(t)$ 分离出第一个 PF 分量后, 剩余信号设为 $u_1(t)$, 对该信号重复以上分解步骤, 循环 k 次, 直至 $u_k(t)$ 为单调函数, 则已分离出所有 PF 分量, 迭代过程为:

$$u_k(t) = u_{k-1}(t) - PF_k \quad (3)$$

可将原始信号 $u(t)$ 表示为剩余量和乘积函数分量之和:

$$u(t) = \sum_{i=1}^k PF_i + u_k(t) \quad (4)$$

1.2 基于自适应信号的改进 LMD 分解

LMD 属于自适应信号分解法, 由于滑动平滑处理长度限制, 信号的端点是否是极值点难以判断, 因此会造成计算误差。经过多次分解对分解结果有较大的影响, 因此存在一定的端点效应。

针对改进的 LMD 算法, 已有学者采用了滑动

平滑、3 次 B 样条插值等方法进行了试验研究,并取得了一定的成果^[11]。本研究设计一种基于信号自适应的方法对信号两端进行延拓,抑制 LMD 分解存在的端点效应。

以左延拓为例,设信号 $x(t)$ 的极大值和极小值分别为 m_i 和 n_i ,对应的时间为 t_{mi} 和 t_{ni} ,设左端点开始首个数据 $x_1(t)$,对应的首个极大值极小值为 m_1 和 n_1 ,则由这三个点可以构成一个三角形,作为匹配标准在原始信号内部寻找最匹配波形,向左端点以左延拓信号。

该端点延拓步骤如下。

1) 确定匹配三角形波形端点,设该点值为 $x(i)$,则所对应的时间 $t_{x(t)}$ 为:

$$t_{x(t)} = \frac{t_{m_1} t_{n_i} - t_{n_1} t_{m_i}}{t_{m_1} - t_{n_1}} \quad (5)$$

2) 计算匹配三角波形和左延拓波形误差 e :

$$e(i) = |m_i - m_1| + |n_i - n_1| + |x(i) - x(1)| \quad (6)$$

从计算匹配误差中选择最小值 \min ,设定为范围 z 。当 $\min < z$,则匹配存在误差;当 $\min \geq z$,则可计算端点处的极大值和极小值。

3) 计算端点附近若干极大值和极小值的平均值,作为原始信号 $x(t)$ 的极大值和极小值。同理,对右端点也可进行相同的延拓,生成延拓后的信号 $x(t)'$,再采用 LMD 常规步骤进行信号的分析与处理。

为对改进 LMD 的端点效应做出评价,设定端点效应评价指标为:

$$\varphi = \frac{\left| \sqrt{\sum_{i=1}^{k+1} R_i^2} - R_x \right|}{R_x} \quad (7)$$

式中: R_x 为原始信号有效值; R_i 为第 i 个 PF 分量的有效值; $(k+1)$ 为 PF 分量总数(其中包括残余项)。

通过式(7)可知,当 $\varphi=0$ 时,则无端点效应; φ 值越大,则端点效应越大。

1.3 改进 LMD 法的信号处理效果分析

1) 延拓 LMD 法与未延拓 LMD 法的比较。

为了验证改进 LMD 信号延拓对端点效应的效果,设定信号: $x(t) = \cos(12\pi t) + \sin(60\pi t) + 2\cos(100\pi t)$,通过式(7)对经过延拓和未经延拓的信号进行分解效果对比。信号分解波形图如图 1 所示。

通过图 1 的(b1),(b2)和(c1),(c2)波形的对比可见,标准 LMD 分解两层波形后,端点处的波形幅值都出现了明显的增大,改进 LMD 法分解产生的信号在端点附近的波形收敛性更好。同时,由图1(b)和图 1(c)两组图的纵坐标值可见,改进 LMD 法处理后的波形幅值范围明显小于标准 LMD 法处理后的图像。采用式(7)对经过延拓的 LMD 法和未经延拓的 LMD 法进行分解效果对比,结果如表 1 所示。

由表 1 可知,该自适应信号延拓的端点效应评价因子由传统方法的 0.024 5 降低至 0.011 9,评价因子的下降率为 51.4%。该数据表明,基于自适应信号改进的 LMD 分解,通过延拓原始信号可以有效地抑制端点效应,改进后分解效果好。

2) 自适应信号延拓 LMD 法和其他信号延拓方法的比较。

针对 LMD 法可能存在的端点效应,有大量专家学者研究了不同的信号延拓方法以抑制算法产生的端点效应。文献[12]采用镜像延拓,该方法本质并非信号的完全延拓,而是将极值点延拓,每求得一次均值函数与包络函数则需要重新进行极值点延拓。文献[13]中使用 3 次 B 样条差值法对 LMD 法进行了改进。

采用这两种方法进行信号分解后的端点效应评价指标以及对 3 种信号延拓方法进行对比的结果见表 2。

由表 2 可知,3 种方法在延拓处理信号后都能有效地降低 LMD 的端点效应,本研究采取的自适应信号延拓方法处理后的端点效应评价指标较其他两种方法低,说明这种改进的 LMD 法具有实用性,信号分析重构能力强。

表 1 改进 LMD 各层端点效应比较

Table 1 Comparison of original LMD and improved LMD

	未延拓	延拓
φ	0.024 5	0.011 9

表 2 各延拓方法端点效应评价比较

Table 2 Comparison of various LMD endpoint extension methods

	未延拓算法	延拓算法
自适应信号延拓	0.024 5	0.011 9
镜像延拓	0.029 0	0.013 0
3 次 B 样条插值	0.044 8	0.021 3

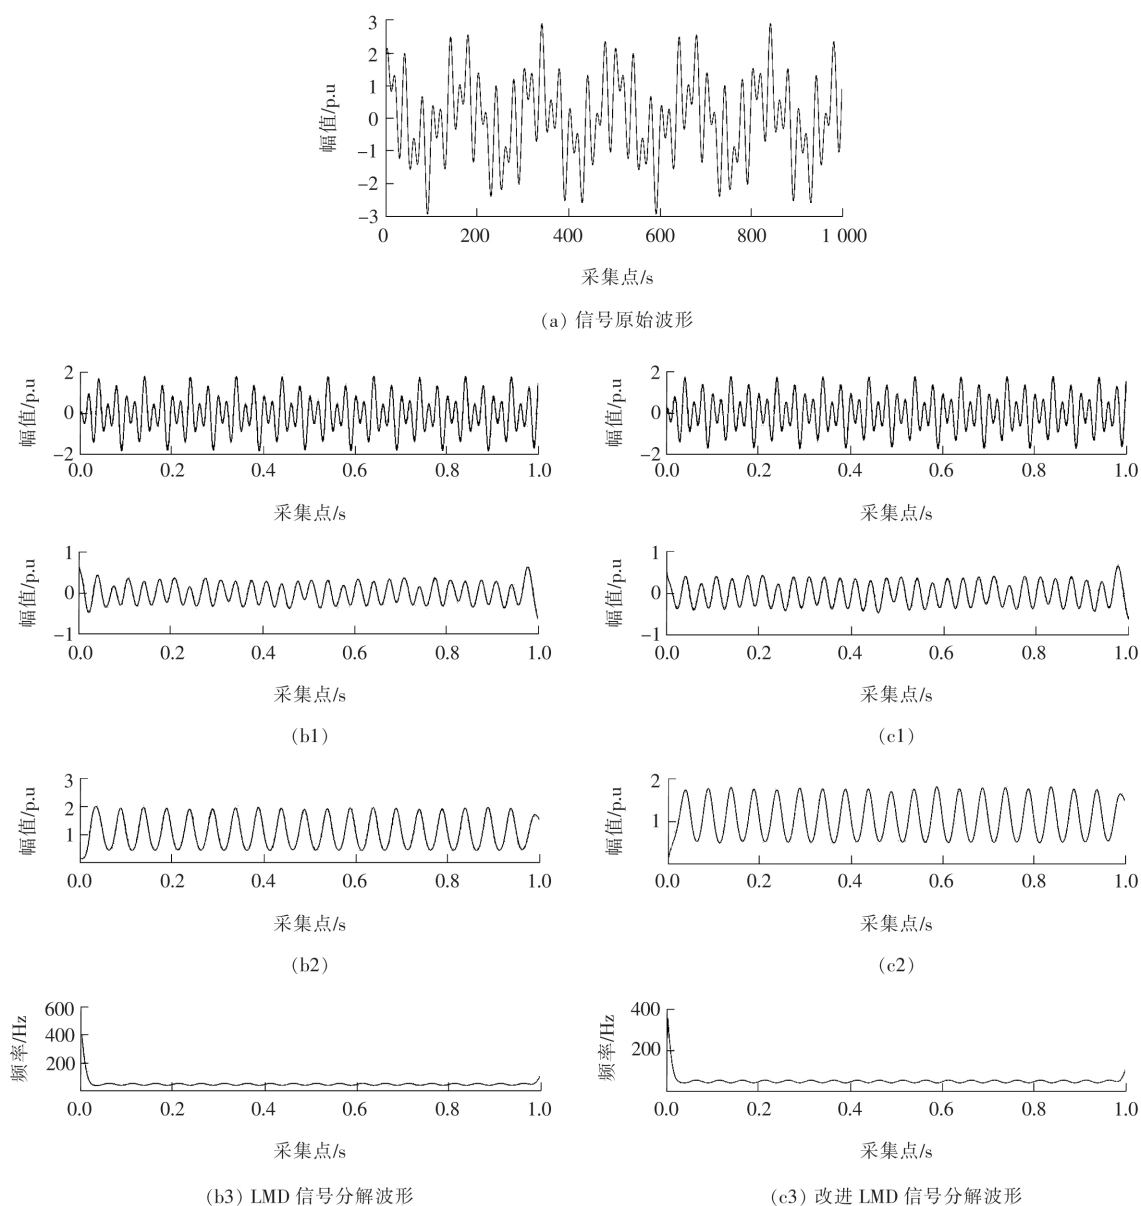


图1 基于标准 LMD 和改进 LMD 的信号分解波形比较

Fig. 1 Comparison of signal decomposition between standard and improved LMD

2 基于 ILMD 的电压扰动信号分解

在实际的电力系统中,电压并非理想状态。由于非线性负荷、冲击负荷、外部干扰以及各种故障因素,导致电力系统电压信号中存在各种暂态扰动。根据 IEEE 1159-2009 标准,本研究采用改进的 LMD 法对电压暂降、电压中断、电压暂态振荡和电压频率偏移这四种典型电压扰动信号进行分析检测。

根据电力系统要求,设电压信号频率为工频

50 Hz,采集率为 5 000,每组信号取 1 000 组采样点进行 MATLAB 仿真试验。信号函数中的 $\varepsilon(t_1)$ 和 $\varepsilon(t_2)$ 为阶跃函数,表征扰动的起止时间,其中, $t_1=0.062\ 5$, $t_2=0.25$ 。

1) 电压暂降信号。

设电压暂降信号为:

$$u(t)=\{1-0.2[\varepsilon(t_2)-\varepsilon(t_1)]\}\sin\omega t。$$

2) 电压中断信号。

设电压中断信号为:

$$u(t)=\{1-0.99[\varepsilon(t_2)-\varepsilon(t_1)]\}\sin\omega t。$$

3) 电压振荡信号。

设电压振荡信号为:

$$u(t) = \sin \omega t + 0.7e^{-20(t-t_1)} \cdot [\epsilon(t_2) - \epsilon(t_1)] \sin 10\omega t。$$

4) 电压频率偏移信号。

设电压偏移信号为:

$$\begin{cases} \sin \omega t; t < t_1, t > t_2 \\ \sin \omega_1 t; t_1 \leq t \leq t_2, \omega_1 = 40 \text{ Hz}^\circ \end{cases}$$

针对 4 种典型扰动信号进行基于改进 LMD 法的信号分解,由图 1~5 可知,它们不仅原始信号波形不同,而且在频率、幅值方面均存在明显的

差异。对比图 1 和图 2 可以看出,电压暂降信号和电压中断信号频率波形基本一致,但是幅值存在较大区别;而在图 1 和图 4 中,电压暂降信号与电压频率偏移信号有基本一致的幅值波形,但频率波形不一致。因此,仅根据其中一项对信号类型进行分析判断有可能存在误判。加之实际电压扰动时间短,无法明确分辨扰动情况的具体信息,因此通过构建电压扰动分类器,结合信号自身的多方面信息,可实现电压扰动的准确快速分类。

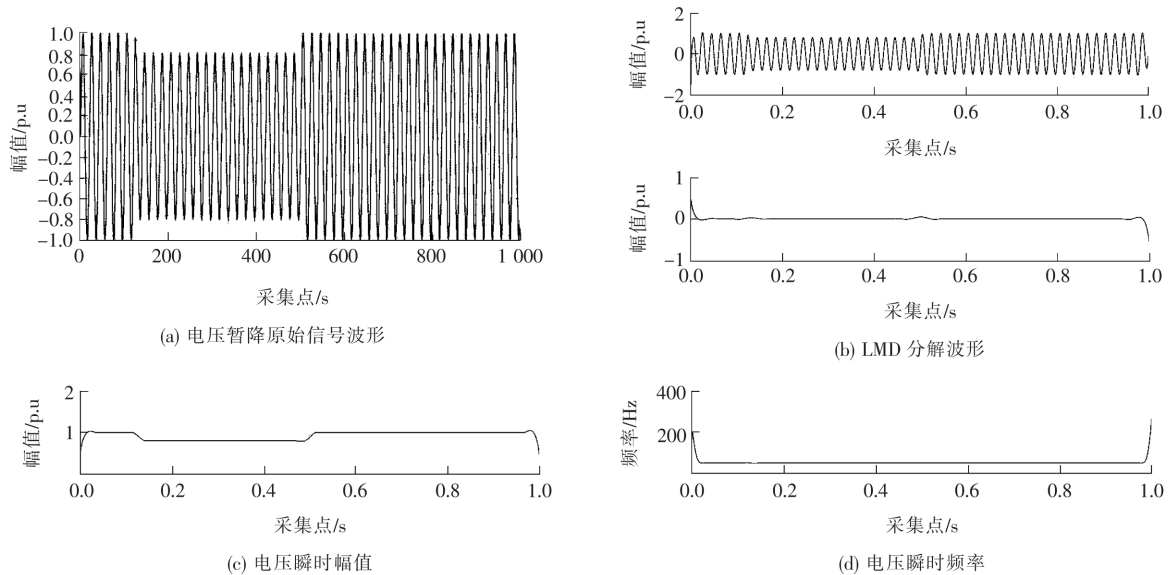


图 2 电压暂降信号 LMD 分解

Fig. 2 LMD decomposition of voltage dip signal

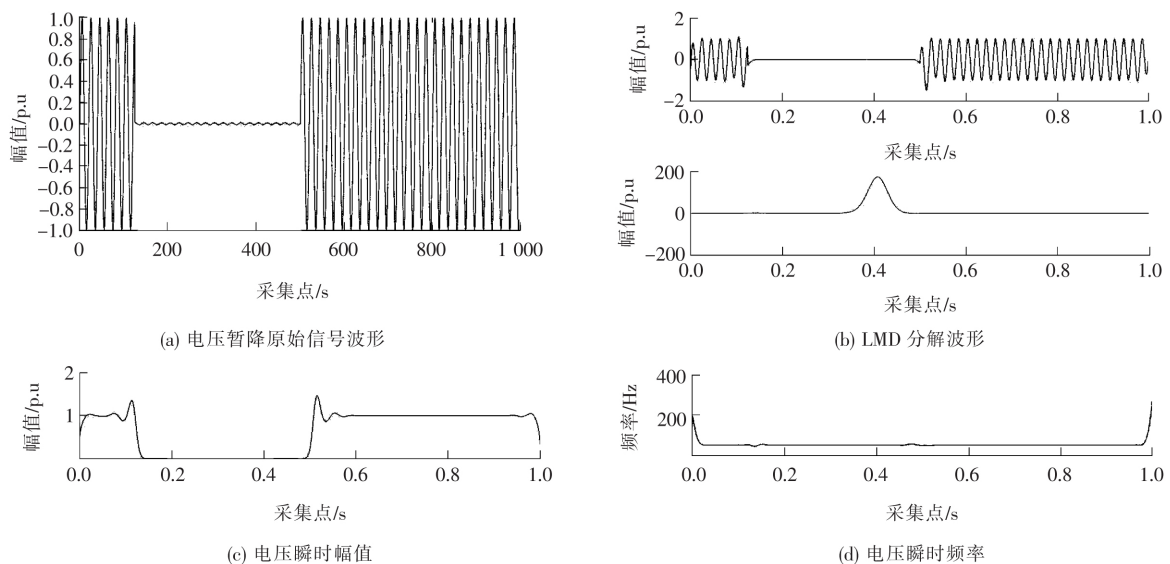


图 3 电压中断信号 LMD 分解

Fig. 3 LMD decomposition of voltage interruption signal

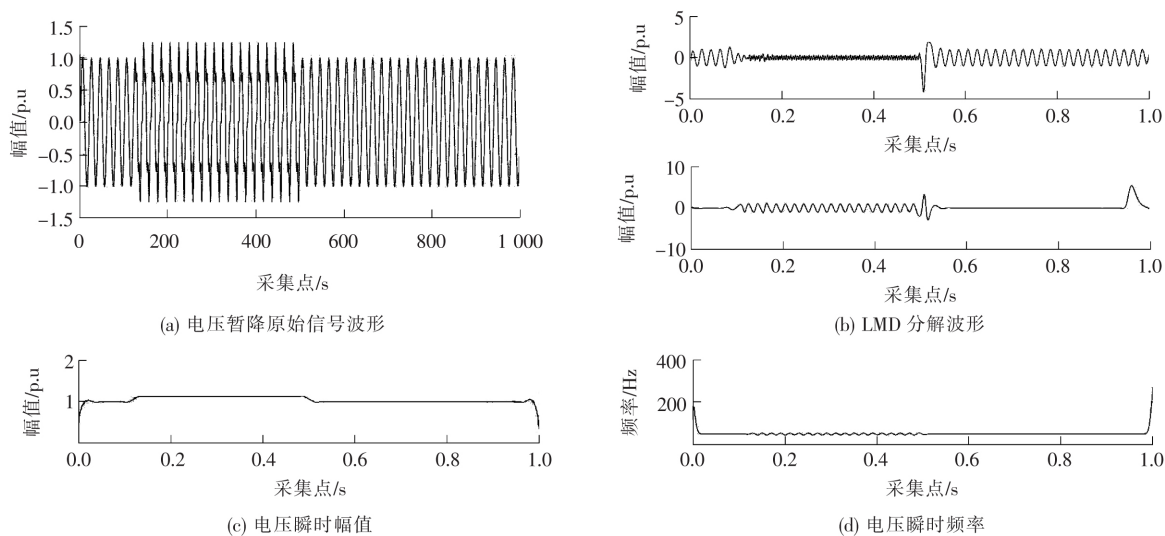


图4 暂态振荡信号 LMD 分解

Fig. 4 LMD decomposition of transient oscillation signal

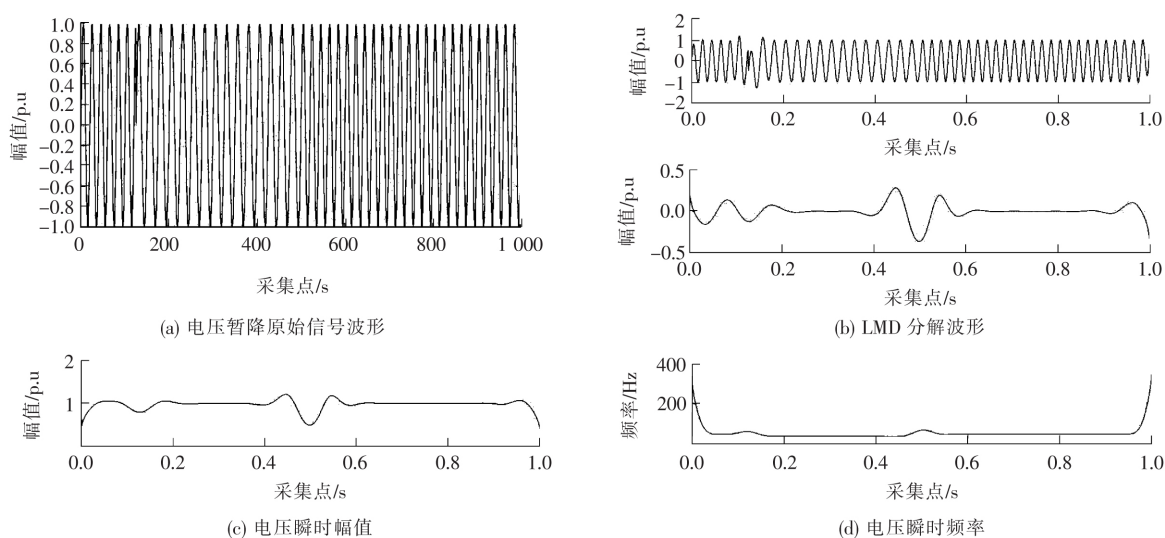


图5 频率偏移信号 LMD 分解

Fig. 5 LMD decomposition of frequency deviation signal

3 基于改进 LMD 与神经网络的电压扰动分类器

3.1 基于 LMD 与神经网络信号分类原理

BP 神经网络的学习过程包含信息正向传播过程和误差反向传播的神经网络结构,具有良好的样本学习和数据分类能力。

本研究采用 BP 神经网络与 LMD 法相结合的方法进行电压扰动信号的分类识别。该方法构成的信号分类器结构如图 6 所示。




图6 基于改进 LMD 与神经网络的信号分类器

Fig. 6 Signal classifier based on improved LMD and neural network

神经网络的运行关键在于选定正确的特征量作为神经网络的输入。基于改进 LMD 法进行信

号分解的电压信号特征量选取所依据的是信号分解后的能量大小 E , 能量特征提取步骤如下。

1) 对信号进行 LMD 分解。每种信号进行 3 层 LMD 分解, 选取包含每层幅值、频率的 3 个 PF 分量。

2) 求得不同信号在 LMD 分解下每层 PF 分量的总能量 E_i :

$$E_i = \int_{-\infty}^{+\infty} |PF_i(t)|^2 dt. \quad (8)$$

3) 以能量 E_i 为元素构造特征向量 T :

$$T = [E_1, E_2, E_3]. \quad (9)$$

由于能量数值相对较大, 为便于后期数据处理, 对向量特征 T 进行归一化处理。令 $E = (\sum_{i=1}^5 |E_i|^2)^{1/2}$, 则归一化之后的向量 T 为: $T = [E_1/E, E_2/E, E_3/E]$ 。

将归一化后能量值形成序列 c_1, c_2, c_3, c_4 (依次代表电压暂降、电压中断、电压暂态振荡和电压频率偏移这四种信号类型), 并构成特征向量 T , 该特征向量 T 作为神经网络的输入量, 得到的特征值列于表 3 中。

表 3 4 种扰动信号能量归一化特征向量

Table 3 Energy normalized eigenvector of 4 kinds of disturbance signals

扰动类型	序号	特征向量		
		E_1/E	E_2/E	E_3/E
电压暂降	1	0.912 2	0.070 2	0.035 4
	2	0.905 7	0.062 3	0.041 7
	3	0.922 9	0.043 7	0.035 5
电压中断	1	0.850 3	0.102 5	0.048 9
	2	0.856 1	0.094 5	0.052 1
	3	0.849 1	0.091 8	0.062 5
暂态振荡	1	0.640 2	0.147 6	0.203 2
	2	0.641 7	0.155 2	0.210 3
	3	0.649 8	0.146 1	0.221 8
频率偏移	1	0.973 2	0.021 0	0.013 3
	2	0.965 8	0.019 2	0.011 5
	3	0.974 3	0.016 6	0.011 7

3.2 电压扰动类型的判别和验证

本研究采用的 BP 神经网络, 网络结构为 3 层, 分别将电压暂降、电压中断、暂态振荡和频率

偏移的特征向量 T 作为神经网络的输入, 隐含层神经元个数为 4, 输出分别对应电压暂降、电压中断、暂态振荡和频率偏移 4 种模式。对 4 种扰动信号模式每组 250 个样本共 1 000 个样本进行训练, 网络训练收敛则停止, 控制误差为 0.001。

对训练样本的 4 种类型每组 250 个信号三层分解后归一化能量值进行 K-means 运算, 以设定能量值的判定标准。K-means 算法通过选取 250 个信号中的 n 个对象作为初始聚类中心, 对剩下的 $(250-n)$ 个对象与聚类中心求取相似度, 得到新的聚类中心后继续迭代运算, 是典型的基于距离的聚类算法。采用距离作为相似性的评价指标, 即认为两个对象的距离越近, 其相似度就越大。通过 K-means 算法, 设定 4 种不同电压扰动信号能量值的判定标准为:

电压暂降: $c_{10} = [0.915\ 1, 0.120\ 2, 0.042\ 3]$ 。

电压中断: $c_{20} = [0.831\ 6, 0.121\ 7, 0.072\ 8]$ 。

暂态振荡: $c_{30} = [0.554\ 2, 0.247\ 9, 0.250\ 8]$ 。

频率偏移: $c_{40} = [0.988\ 2, 0.036\ 9, 0.018\ 9]$ 。

根据模糊理论中最小平均贴度原则, 将学习输出后的归一化能量值与设定的判定标准进行贴度比较, 检验信号分类的正确性。检验过程选取 4 种扰动信号类型, 每种各 2 个样本信号, 对 8 个测试样本做标准化处理后计算测试样本和标准样本的贴度, 每组测试样本和标准样本的最小平均贴度用 $\delta_i (i=1, 2, 3, 4)$ 表示。本研究检测采用的最小平均贴度计算公式为:

$$\delta = N(A_i, B) = \frac{2 \sum_{i=1}^n [A(u_i) \wedge B(u_i)]}{\sum_{i=1}^n [A(u_i) + B(u_i)]}. \quad (10)$$

式(7)中, A_i, B 为定义内的两个集合, 选定 A_i 集合分别为 4 种扰动信号判定标准 (即 c_1, c_2, c_3, c_4), B 集合为分解后的校验信号能量值, 式(7)中 $A(u_i) \wedge B(u_i)$ 是对 A_i, B 两个集合进行交运算。当校验所需的 8 个扰动信号分解输出后, 与 4 种不同判定标准进行贴度计算, 将对应的 4 种信号的检测结果分类为 F_1, F_2, F_3, F_4 (分别代表电压暂降、电压中断、电压暂态振荡、电压频率偏移 4 种信号类型)。通过样本信号与判定标准的贴度计算结果可以得到: δ_3 值最大时, 输入为电压暂降信号, 对应 F_1 ; δ_2 值最大时, 输入为电压中断信号, 对应 F_2 ; δ_1 值最大时, 输入为暂态振荡信

号,对应 F_3 ; δ_4 值最大时,输入为频率偏移信号,对应 F_4 。根据以上判定标准,8 个校验信号的检测结果如表 4 所示。

表 4 扰动信号检测结果

Table 4 Detection result of disturbance signals

	δ_1	δ_2	δ_3	δ_4	结果
F_1	0.801 5	0.799 6	0.993 1	0.412 1	正确
	0.805 5	0.800 1	0.992 3	0.397 6	正确
F_2	0.802 7	0.996 1	0.796 7	0.291 2	正确
	0.789 5	0.985 7	0.798 1	0.278 7	正确
F_3	0.987 1	0.375 3	0.448 9	0.596 1	正确
	0.991 3	0.392 2	0.469 1	0.607 2	正确
F_4	0.691 2	0.770 6	0.528 7	0.987 1	正确
	0.701 1	0.792 8	0.495 1	0.985 6	正确

根据贴近度原则,从表 4 可以看出, F_1 组 δ_3 值最大,为电压暂降信号; F_2 组 δ_2 值最大,为电压中断信号; F_3 组 δ_1 值最大,为暂态振荡信号; F_4 组 δ_4 值最大,为频率偏移信号。

将原始信号和校验信号($F_1 \sim F_4$ 组,共 8 个)两者分别与判断标准($c_{10} \sim c_{40}$)贴近度计算的数值进行对比,可知检测的扰动信号与原设定信号结果相符。通过该信号分类器处理后的准确率高,证明了基于改进 LMD 的 BP 神经网络在对 8 组扰动信号处理中做出了正确的判断。

4 结论

针对电力系统电压存在扰动现象,作者基于 ILMD 法与 BP 神经网络相结合构成电压扰动信号分类器,通过理论分析和试验得到以下结论。

1) 对传统 LMD 法改进,通过信号本身构建三角波形对扰动信号进行自适应信号延拓,延拓后的扰动信号端点效应评价系数明显减小,该改进方法可以有效抑制传统 LMD 法的端点效应。

2) 采用 ILMD 和 BP 神经网络构成的扰动信号分类器,对信号进行 3 层 ILMD 分解,得到包含信号频率、幅值信息的 PF 分量,将该分量作为 BP 神经网络的输入值,可以实现对信号的识别与分类。

3) 通过对系统中 4 种典型电压扰动信号进行试验,证明了 ILMD 法信号分解效率高。结合 BP 神经网络进行信号识别分类,能减少重复迭代次

数,识别效率较高,识别电压扰动信号的准确性也较高。

〔参考文献〕

- [1] 侯建兰,马冰,刘育权,等.电网暂态电压稳定的主要影响因素量化分析[J].电网与清洁能源,2016,32(6):28—34.
HOU Jian-lan, MA Bing, LIU Yu-quan, et al. Quantitative analysis of main factors influencing transient voltage stability of power grid[J]. Power System and Clean Energy, 2016, 32(6): 28—34.
- [2] 桑博,刘洪文,尹志勇.单一电能质量扰动的分类识别研究[J].国外电子测量技术,2016,35(7):56—59.
SANG Bo, LIU Hong-wen, YIN Zhi-yong. Research of signal power quality disturbance identification and classification[J]. Foreign Electronic Measurement Technology, 2016, 35(7): 56—59.
- [3] 张逸,林焱,吴丹岳.电能质量监测系统研究现状及发展趋势[J].电力系统保护与控制,2015(2):138—147.
ZHANG Yi, LIN Yan, WU Dan-yue. Current status and development trend of power quality monitoring system[J]. Power System Protection and Control, 2015(2): 138—147.
- [4] 黄建明,瞿合祚,李晓明.基于短时傅里叶变换及其谱峭度的电能质量混合扰动分类[J].电网技术,2016,40(10):3184—3191.
HUANG Jian-ming, ZHAI He-zuo, LI Xiao-ming. Classification for hybrid power quality disturbance based on STFT and its spectral kurtosis[J]. Power System Technology, 2016, 40(10): 3184—3191.
- [5] 关维国,姚清志,高阳,等.基于 db4 小波的配电网暂态电能质量扰动的检测与定位[J].电力系统保护与控制,2015(8):102—106.
GUAN Wei-guo, YAO Qing-zhi, GAO Yang, et al. Transient power quality detection and location of distribution network based on db4 wavelet transform [J]. Power System Protection and Control, 2015(8): 102—106.
- [6] Koley E, Kumar R, Ghosh S. Low cost microcontroller based fault detector, classifier, zone identifier and locator for transmission lines using wavelet transform and artificial neural network: a hardware co-simulation approach[J]. International Journal of Electrical Power and Energy Systems, 2016(81): 346—360.
- [7] 肖助力,龚仁喜,陈双,等.基于改进 S 变换的电力系

- 统谐波检测方法[J].电力系统保护与控制,2015(3):84—90.
- XIAO Zhu—li, GONG Ren—xi, CHEN Shuang, et al. Detection of harmonics in power system based on modified S—transform[J]. Power System Protection and Control, 2015(3):84—90.
- [8] 吕帅,张靠社.基于小波变换去噪预处理的 EMD 谐波检测方法[J].电网与清洁能源,2016,32(6):58—61.
- LV Shuai, ZHANG Kao—she. EMD harmonic detection method of denoising preprocessing based on wavelet transform[J]. Power System and Clean Energy, 2016, 32(6):58—61.
- [9] Smith J S. The local mean decomposition and its application to EEG perception data[J]. Journal of the Royal Society Interface, 2005, 2(5):443—454.
- [10] 焦李成,杨淑媛,刘芳,等.神经网络七十年:回顾与展望[J].计算机学报,2016,39(8):1697—1716.
- JIAO Li—cheng, YANG Shu—yuan, LIU Fang, et al. Seventy years beyond neural networks: retrospect and prospect[J]. Chinese Journal of Computers, 2016, 39(8):1697—1716.
- [11] 宋海军,黄传金,刘超宏,等.基于改进 LMD 的电能质量扰动检测新方法[J].中国电机工程学报,2016,28(8):74—78.
- SONG Hai—jun, HUANG Chuan—jin, LIU Chao—hong, et al. A new power quality disturbance detection method based on the improved LMD[J]. Proceedings of the CSEE, 2016, 28(8):74—78.
- [12] 杜培伟,黄纯,王美,等.基于改进 LMD 的谐波扰动检测新方法[J].电力系统及其自动化学报,2016,28(8):74—78.
- DU Pei—wei, HUANG Chun, WANG Mei, et al. New method of harmonic disturbance detection based on improved LMD[J]. Proceedings of the CSU—EPSA, 2016, 28(8):74—78.
- [13] 任达千,杨世锡,吴昭同,等.LMD 时频分析方法的端点效应在旋转机械故障诊断中的影响[J].中国机械工程,2012,23(8):951—956.
- REN Da—qian, YANG Shi—xi, WU Zhao—tong, et al. Research on end effect of LMD based time—frequency analysis in rotating machinery fault diagnosis[J]. China Mechanical Engineering, 2012, 23(8):951—956.
-
- (上接第 39 页)
- CHEN Fu—ying, HU Zhi—hua. Analysis of shipping network of Southeast—Asian route along maritime silk road based on complex networks[J]. Shanghai University: Natural Science, 2016, 22(6):804—812.
- [2] 李电生,张腾飞,钟丹阳.基于港口航运网拓扑结构的港口层次划分:以中国城市港口航运网为例[J].中国海洋大学学报:社会科学版,2017(2):85—90.
- LI Dian—sheng, ZHANG Teng—fei, ZHONG Dan—yang. Port hierarchy partition based on the topological structure of port shipping network: an empirical study on ports of Chinese cities and shipping network[J]. Ocean University of China Social Science, 2017(2):85—90.
- [3] Wilmsmeier G, Monios J, Pérez—Salas G. Port system evolution: the case of Latin America and the Caribbean[J]. Journal of Transport Geography, 2014, 39(39):208—221.
- [4] 蒋柳鹏,封学军,王伟.“港口—产业—城市”复合系统协调度模型[J].水利经济,2011,29(1):11—14.
- JIANG Liu—peng, FENG Xue—jun, WANG Wei. "Port—Industry—City" composite system coordination model[J]. Economics of Water Resources, 2011, 29(1):11—14.
- [5] 蹇令香,李东兵,刘玲玲.我国集装箱港口体系演进规律研究[J].经济地理,2012,32(12):91—96.
- JIAN Ling—xiang, LI Dong—bing, LIU Ling—ling. Research on the evolution law of China container port system[J]. Economic Geography, 2012, 32(12):91—96.
- [6] Ducruet C. Multilayer dynamics of complex spatial networks: the case of global maritime flows(1977—2008)[J]. Journal of Transport Geography, 2017(60):47—58.
- [7] 迪克吕特,王列辉.中国的全球航运连通性:当代内部和外部的动态(1890—2016)[J].中国地理科学,2018(2):202—216.
- Ducruet C, Wang L. China's global shipping connectivity: internal and external dynamics in the contemporary era(1890—2016)[J]. Chinese Geographical Science, 2018(2):202—216.
- [8] Newman M E J. Detecting community structure in networks[J]. European Physical Journal B, 2004, 38(2):321—330.
- [9] Newman M E J. Fast algorithm for detecting community structure in networks[J]. Physical Review E Statistical Nonlinear and Soft Matter Physics, 2004, 69(6):066133.