

基于EMD近似熵和RBF神经网络的换流器故障诊断

提出了基于经验模式识别(EMD)近似熵和径向基函数(RBF)神经网络的换流器故障诊断方法。通过对故障信号EMD分解提取故障信号特征,得到多个可以反映故障特征的本征模式分量(IMF),选取反映信号主要信息的IMF分量并求解其近似熵,从而构造各种故障的特征矩阵,并作为样本运用RBF神经网络进行训练。换流器故障时,将所提取的故障信号特征矩阵输入已训练好的RBF网络,从而可实现故障类型的识别。仿真证明,该方法能够有效提取出不同故障的特征,从而区分换流器各类故障,具有很好的可行性。

刘霄涵 王渝红 李兴源 魏 亮/四川大学电气信息学院



刘霄涵/硕士研究生

目前,国内外对换流器内部电路的故障诊断问题研究较少^[1-5]。文献[1]直接运用故障信号作为故障特征向量,运用人工神经网络方法实现故障的诊断;文献[2]提出了运用独立分量法对噪声信号进行抑制,并运用支持向量机的方法对换流器故障进行诊断;文献[3]分析了各种故障特征,并基于小波分析方法提取故障的特征向量,并将其作为样本运用人工神经网络方法训练,以实现故障的识别。

本文提出了一种换流器故障检测的方法,该方法基于经验模式识别(EMD),对不同监测信号进行故障特征提取,然后运用近似熵量化处理。最后通过神经网络对样本进行训练,得到分类器模型并对其准确性进行测试。仿真证明,运用该方法进行的换流器故障检测准确度较高,具有良好的可行性。

国家自然科学基金资助项目(51037003)。

关键词/Keywords

经验模式识别·
近似熵·
径向基函数·
神经网络·
换流器故障·
故障诊断·

基本原理

1. 换流器结构及故障类型

换流器是实现高压直流输电中交—直—交转换的核心设备。换流阀通过触发脉冲信号控制晶闸管的导通,换流阀由多个阀组构成,且阀组由多个阀构成。6脉动换流器接线原理图如图1所示^[6-7]。




图1 6脉动换流器接线原理图

换流器故障是指换流器自身及其相关部件非正常运行的状态与过程。自身故障包括换流器内部闪络、短路和换流器触发脉冲回路故障等;相关部件故障包括换流器相连交直流系统故障引起的换流器异常工作等。常见的换流器故障可以分为以下6种情况,如图2所示。




图2 常见换流器故障类型

F₁—阀臂短路 F₂—阀臂开路 F₃—直流侧接地故障
F₄—交流侧单相接地短路故障 F₅—交流侧两相接地故障
F₆—交流侧三相接地短路故障

2. EMD基本原理

EMD是一种对信号进行时频分析的

方法,也就是将信号中各个尺度的波动以及趋势逐步提取出来,分解成不同频率的IMF分量。这是一种平稳化处理的过程,所产生的每一个序列称之为固有模态函数。IMF分量满足如下规律:极值点数和零点相等,或者相差1个;上下包络线均值为0。

运用EMD分解信号 $f(t)$ 时,首先要确定信号的局部极值点,再画出上下包络线并求出上包络线与下包络线平均值 a_1 ,则 $h_1=f(t)-a_1$,此时若 h_1 能够使IMF的条件成立,则它即为第一个分量。

其次,若 h_1 不能使IMF的条件成立,则令其为起始数据,重复上一步 k 次直到满足条件,得到 $h_{1(k-1)}-a_{1k}=h_{1k}$,记做 $c_1=h_{1k}$, c_1 即为第一个满足条件的分量并将其从 $f(t)$ 中分离出来, $g_1=f(t)-c_1$ 。

最后, g_1 作为起始数据重复上述步骤 n 次,直到 c_n 成为单调函数,无法提取IMF分量,即结束循环,可得到满足条件的 n 个分量,可以表示为 $c_1, c_2, \dots, c_n$,即

$$f(t)=\sum_{j=1}^n c_j+r_n \quad (1)$$

式中, r_n 为余项,即表达了信号平均趋势。

在上述分解过程中,初始信号的自身特性被保留了下来,信号的特征在不同分辨率下表示出来,因而IMF能够提供更多的特征信息^[8-10]。

3. 近似熵基本原理

近似熵能用于度量序列的复杂性,时间序列越复杂,对应的近似熵越大,也就是说,近似熵是从衡量信号的复杂性角度去度量产生新的模式概率的大小,产生新模式概率愈大,信号复杂性愈大,近似熵亦愈大。

近似熵的算法如下^[11-13]。

1) 序列 $\{u(i)\}$ 按顺序组成 m 维的矢量 $X(i)$,表示为

$$X(i)=[u(i), u(i+1), \dots, u(i+m-1)] \quad i=1 \sim N-m+1 \quad (2)$$

2) 每个 i 值都计算矢量 $X(i)$ 与其他 $X(j)$ 间距离,表示为

$$d[X(i), X(j)]=\max_{k=0 \sim m-1} |u(i+k)-u(j+k)| \quad (3)$$

3) 给定阈值 r (满足 $r>0$),每个 i 值统计 $d[X(i), X(j)]<r$ 的数目与矢量总数 $N-m+1$ 的比

值,即

$$C_i^m(r)=\{d[X(i), X(j)]<r \text{ 个数}\}/(N-m+1) \quad (4)$$

4) 对 C_i^m 取对数,然后求其对所有 i 的平均值,即

$$\Phi^m(r)=\frac{1}{N-m+1} \sum_{i=1}^{N-m+1} \ln C_i^m(r) \quad (5)$$

5) $m=m+1$,重复步骤1~4,得到 $\Phi^{m+1}(r)$ 。

6) 该序列近似熵理论上应为

$$\text{Apen}(m, r, N)=\lim_{N \rightarrow \infty} [\Phi^m(r)-\Phi^{m+1}(r)] \quad (6)$$

然而实际计算时, N 为有限值,那么近似熵估计值可以表示为

$$\text{Apen}(m, r, N)=\Phi^m(r)-\Phi^{m+1}(r) \quad (7)$$

通常 $m=2$, $r=0.1 \sim 0.25SD_x$ 时,近似熵的统计特性较为合理。

4. RBF神经网络

典型RBF神经网络是一个具有单隐层的3层前馈网络,模拟人脑中的局部调整和相互覆盖接收域,其结构如图3所示。第一层为输入层,是由信号源节点组成的;第二层为隐含层,隐层节点即RBF节点;第三层为输出层,通常由线性神经元构成。隐含层的神经元的数量是输入的样本点决定的,而输出层神经元的数量则是由待分辨的故障模式及类型所决定的^[14-15]。




图3 RBF神经网络结构图

单输出RBF网络隐层的第 i 个单元输出为

$$u_i(x)=R_i(x)=R_i(\|x-c_i\|/\sigma_i) \quad (8)$$

式中, $i=1,2,\dots,N$ (N 为隐层单元数); x 为 X 维的输入向量; c_i 是与 x 维数相同的中心向量; σ_i 决定隐层单元域的大小; $R_i(x)$ 为隐层的第 i 个单元的激励函数。

网络的输出是隐层单元输出值加权求和,即

$$f(x)=\sum_{i=1}^N f_i R_i(x) \quad (9)$$

式中, f_i 为从隐层的第 i 个单元到输出层的权值。

网络输出亦可用加权平均的方式, 即

$$f(\mathbf{x}) = \sum_{i=1}^N f_i R_i(\mathbf{x}) / \sum_{i=1}^N R_i(\mathbf{x}) \quad (10)$$

基于EMD近似熵和RBF神经网络的换流器故障识别法

换流器故障时, 各监测信号含有大量高频暂态分量信号, EMD能够自适应地将所监测的故障信号分解, 得到各IMF分量, 这个过程是故障特征提取的过程, 即IMF相较于原始信号更能反映对应故障的信息。尽管不同故障信号求取的IMF分量个数不尽相同, 组前10个IMF分量已经包含了故障的主要信息, 因此首先对故障后的多个监测信号进行EMD分析, 得到对应的各IMF, 取前10个IMF分量进行分析。

为了分析各IMF信号的复杂性, 求解各分量的近似熵, 信号愈是复杂, 对应的近似熵值愈大。每种故障时多个监测信号的IMF分量进行近似熵求解, 则故障信息蕴含于近似熵的大小及变化趋势中。对每个监测信号 $(X^1, X^2, \dots, X^n)$ 的前10个IMF分量求取近似熵值, 表示为 $X_{S_{n1}}^1, X_{S_{n2}}^1, \dots, X_{S_{n10}}^1$; $X_{S_{n1}}^2, X_{S_{n2}}^2, \dots, X_{S_{n10}}^2$; $\dots$; $X_{S_{n1}}^n, X_{S_{n2}}^n, \dots, X_{S_{n10}}^n$ 。

为了便于识别, 此处将每个信号求取的10个近似熵值组成一个 n 行10列的矩阵, 即

$$\mathbf{V} = \begin{pmatrix} X_{S_{n1}}^1 & X_{S_{n2}}^1 & \dots & X_{S_{n10}}^1 \\ X_{S_{n1}}^2 & X_{S_{n2}}^2 & \dots & X_{S_{n10}}^2 \\ \vdots & \vdots & \ddots & \vdots \\ X_{S_{n1}}^n & X_{S_{n2}}^n & \dots & X_{S_{n10}}^n \end{pmatrix} \quad (11)$$

RBF神经网络能够以任意的准确度逼近任何非线性的函数, 其收敛性与训练速度要优于BP神经网络, 为了求取大量训练样本, 在不同故障时刻、过渡电阻、故障持续时间和故障位置情况下进行大量仿真, 得到足够的训练样本, 再使用RBF神经网络进行训练。

实际系统中换流器故障时, 首先对各个监测信号EMD进行分解, 求得近似熵对应矩阵, 将其输入已经训练好了的RBF神经网络故障分类器中, 即可识别故障类型。

仿真分析

在ADPSS的ETSDAC中, 搭建某 ± 500 kV 的直流输电系统模型。该直流输电系统额定容量为 3 000 MW, 单极运行功率为 1 500 MW, 额定直流电压为 ± 500 kV。一个极为基本运行单元, 每端采用一个12脉动换流器, 即由两个交流侧电压相位相差 30° 的6脉动换流器组成。

共模拟图2中6种换流器故障 $F_1 \sim F_6$, 可以得到多个监测信号的故障数据, 此处选取直流线路电流、逆变侧交流电压有效值、逆变侧交流电流有效值和阀臂电流4个信号作为监测信号, 因而最终得到的矩阵 $\mathbf{V}$ 将是一个4行10列的矩阵。

以直流线路电流为例, 各种故障情况以及正常情况下直流线路电流如图4~图10所示。



图4 正常运行时的直流电流




图5 阀臂短路 (F_1) 时的直流电流




图6 阀臂开路 (F_2) 时的直流电流












图7 直流侧接地短路 (F_3) 时的直流电流

图8 交流侧单相接地短路 (F_4) 时的直流电流图9 交流侧两相短路 (F_5) 时的直流电流图10 交流侧三相接地短路 (F_6) 时的直流电流

通过图4~图10可以看出,6种不同故障情况下,直流线路电流的波动情况互不相同,其中阀臂短路及阀臂开路导致电流的波动情况略微小于其他几种故障;同样,仅通过观察波形,其他监测信号所能够给出的信息也仅限于此。为了进一步提取每种故障的特征,下一步将对各监测信号EMD进行分解。

此处以阀臂短路为例,给出了阀臂短路情况下直流线路电流的EMD分解的前10个分量,通过图11~图15可以看出,通过EMD在不同尺度下的

图11 故障 F_1 时直流侧电流的EMD分量 c_1 、 c_2 图12 故障 F_1 时直流侧电流的EMD分量 c_3 、 c_4 图13 故障 F_1 时直流侧电流的EMD分量 c_5 、 c_6 图14 故障 F_1 时直流侧电流的EMD分量 c_7 、 c_8 图15 故障 F_1 时直流侧电流的EMD分量 c_9 、 c_{10}

分解,阀臂短路的故障特征在各个时间尺度的IMF分量体现出来,前10个IMF分量已经包含了原始信号的主要信息。为了量化各个IMF分量所包含的故障特征信息,接下来对各IMF分量求解近似熵。

EMD分解之后,对各个IMF分量求解其近似熵,6种不同故障下各个监测信号的前10个近似熵值如表1所示。其中,监测信号1:直流线路电流;监测信号2:逆变侧母线电压有效值;监测信号3:逆变侧母线交流侧电流有效值;监测信号4:阀臂电流。

通过表1可以看出,不同故障下同一阶的近似熵各不相同,同一故障下不同阶的近似熵也各不相同;故障越是严重,近似熵就越大,这表示故障越严重所引起的混乱越严重;而且同一监测信号各阶IMF分量的近似熵整体呈现随着分解阶数的增加,近似熵逐渐减小的趋势。

以阀臂短路时的监测信号1的前5个IMF分量为例,画出 $c_1 \sim c_5$ 的概率密度曲线如图16、图17所示。随着分解阶数的增加,IMF分量信号的概率密度曲线越来越尖锐,证实了近似熵随分解阶数增

表1 6种故障下各个监测信号的前10个IMF分量近似熵值

故障类型	监测信号	ApEn1	ApEn2	ApEn3	ApEn4	ApEn5	ApEn6	ApEn7	ApEn8	ApEn9	ApEn10
阀臂短路	1	4.475	4.368	4.161	4.115	3.686	3.875	3.101	3.084	2.394	1.778
	2	4.313	4.094	3.825	3.771	3.414	2.219	2.242	2.217	2.155	2.046
	3	4.157	4.235	3.696	3.669	3.979	3.357	2.621	2.870	2.307	1.147
	4	4.378	4.240	4.247	4.228	3.963	3.349	3.152	2.973	1.601	1.276
阀臂开路	1	4.221	4.307	4.387	4.292	3.448	3.896	2.921	2.476	2.161	1.268
	2	4.597	4.142	4.039	3.522	3.828	3.705	2.822	2.373	0.421	1.179
	3	4.988	4.395	4.089	4.204	3.135	3.649	3.832	3.317	2.399	1.383
	4	4.197	4.418	4.382	4.189	4.011	2.804	2.968	2.221	2.189	2.075
阀直流侧 接地短路	1	4.759	4.342	4.190	4.225	3.432	2.770	2.498	2.394	2.122	1.554
	2	4.430	4.235	4.203	3.743	3.947	3.580	3.001	1.894	1.574	1.331
	3	4.415	4.403	3.992	3.874	3.473	3.250	2.964	2.433	2.007	1.145
	4	4.490	4.353	4.290	4.260	4.168	3.888	3.738	3.526	3.327	3.145
阀交流侧单 相接地短路	1	4.417	4.113	4.403	4.219	4.047	3.830	3.332	3.642	3.875	3.427
	2	4.427	3.967	3.768	3.753	3.711	3.569	2.857	2.710	2.699	2.532
	3	4.310	4.367	4.146	4.088	4.127	3.230	2.741	2.314	1.732	1.171
	4	4.868	4.299	4.165	4.149	3.920	3.851	3.948	3.327	3.103	2.882
阀交流侧 两相短路	1	4.477	4.394	3.139	4.115	4.210	3.417	3.262	2.373	2.305	1.055
	2	4.318	4.352	4.222	4.118	4.206	3.096	2.918	2.531	1.946	0.841
	3	4.287	4.165	4.143	4.034	3.835	3.569	3.258	2.482	2.041	0.256
	4	4.314	4.295	3.932	4.274	4.040	4.021	3.792	3.381	3.522	2.392
阀交流侧三 相接地短路	1	4.989	4.756	4.675	4.304	4.019	3.608	3.695	3.494	1.779	1.235
	2	4.427	4.358	4.288	4.214	3.668	3.796	3.199	2.832	1.978	1.222
	3	4.311	4.245	4.315	4.251	4.100	4.046	4.013	3.647	3.787	1.680
	4	4.378	4.341	4.167	3.950	4.009	4.092	3.840	3.782	3.108	2.891

加而减小，即信号越来越规则，混乱程度也越来越小。




图16 分量 c_1 的概率密度图




图17 分量 $c_2 \sim c_5$ 的概率密度曲线图

采用上述同样的方式，在改变故障发生时间（1 s、2 s、3 s、4 s和5 s）、持续时间（0.1 s、0.15 s、0.2 s、0.25 s和0.3 s）、短路故障过渡电阻（0 Ω 、10 Ω 、20 Ω 、30 Ω 、40 Ω 和50 Ω ）和故障位置（不同阀臂）时，对每一种故障获取50组训练样本，可以得到各类故障情况下的矩阵 V 。此处以过渡电阻为0 Ω ，2 s发生阀臂短路故障，持续时间0.2 s时为例，给出其矩阵 V ，即

$$V^T = \begin{pmatrix} 4.475 & 4.313 & 4.157 & 4.378 \\ 4.368 & 4.094 & 4.235 & 4.240 \\ 4.161 & 3.825 & 3.696 & 4.247 \\ 4.115 & 3.771 & 3.669 & 4.228 \\ 3.686 & 3.414 & 3.979 & 3.963 \\ 3.875 & 2.219 & 3.357 & 3.349 \\ 3.101 & 2.242 & 2.621 & 3.152 \\ 3.084 & 2.217 & 2.870 & 2.973 \\ 2.394 & 2.155 & 2.307 & 1.601 \\ 1.778 & 2.046 & 1.147 & 1.276 \end{pmatrix} \quad (12)$$

最后,通过RBF神经网络对上述样本进行训练,并利用另外50组样本对训练结果的准确性进行测试,可以得到不同故障下测试样本准确个数如表2所示。

表2 不同故障情况下RBF的诊断性能

故障类型	训练样本/个	测试样本/个	准确个数/个
阀臂短路	50	50	47
阀臂开路	50	50	48
阀直流侧接地短路	50	50	50
阀交流侧单相接地短路	50	50	49
阀交流侧两相短路	50	50	47
阀交流侧三相接地短路	50	50	50

通过测试样本的准确数目可以看出,通过对监测信号进行EMD分解,并对各IMF分量求解近似熵,从而提取其故障信号特征,最后运用RBF神经网络实现故障诊断的方法是可行且具有一定可靠性的,且不同过渡电阻、不同故障时间和持续时间,不会影响最终结果。

结束语

提出一种换流阀故障诊断的新方法,即使用EMD对故障监测信号进行分解,求取能反映故障主要信息的各IMF分量的近似熵以量化故障特征,形成故障特征矩阵,最后运用RBF神经网络训练,得到换流阀故障分类器。仿真证明,该方法具有良好的可行性和较高的准确性。

参考文献

- [1] 张家奇,吴坚,于飞.基于神经网络的HVDC系统故障诊断[J].高电压技术,2006,32(5):65-68.
- [2] 李志雄,严新平.独立分量分析和流形学习在VSC-HVDC系统故障诊断中的应用[J].西安交通大学学报,2011,45(2):44-48.
- [3] 孙晓云,同向前,尹军.电压源换流器高压直流输电系统中换流器故障仿真分析及其诊断[J].高电压技术,2012,38(6):1383-1390.
- [4] 林凌雪,张尧,钟庆,等.基于小波能量统计法的HVDC换相失败故障诊断[J].电力系统自动

化,2008,31(23):61-64.

- [5] 孙晓云,同向前,高鑫.柔性直流输电系统中IGBT 阀的故障诊断方法[J].电工技术学报,2014,29(8):235-241,264.
- [6] 韩昆仑,蔡泽祥,李佳曼,等.考虑直流控制的换流器交流侧故障及其保护动作行为分析[J].高电压技术,2014,40(8):2531-2540.
- [7] 郑涛,祁欢欢,范莹.基于阀短路保护的HVDC换流器区内故障定位新方法[J].电力系统自动化,2013,37(5):99-104.
- [8] 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.
- [9] 向丹,葛爽.基于EMD样本熵-LLTSA的故障特征提取方法[J].航空动力学报,2014,29(7):1535-1542.
- [10] 李兴源,朱瑞可,王渝红,等.基于EMD和Prony算法的同步电机参数辨识[J].电网技术,2012,36(8):136-139.
- [11] Pincus S M. Approximate entropy as a measure of system complexity[J]. Proceedings of the National Academy Sciences, USA, 1991, 88(6):2297-2301.
- [12] Hornero R, Alvarez D, Abasolo D, et al. Utility of approximate entropy from overnight pulse oximetry data in the diagnosis of the obstructive sleep spnea syndrome[J]. IEEE Transactions on Biomedical Engineering, 2007, 54(1):107-113.
- [13] 董青迅,李兴源,穆子龙,等.基于近似熵的次同步谐振检测方法[J].电网技术,2011,35(11):103-106.
- [14] Mahanty R N, Gupta P B D. Application of RBF neural network to fault classification and location in transmission line[J]. Proc. Inst. Elect. Eng, 2004, 151(2):201-212.
- [15] 李兴源,宋永华.基于人工神经网络的复杂电力系统故障后电压安全评估[J].中国电机工程学报,1996,16(3):147-150.

(收稿日期:2015-02-10) EA