

基于小波包分解的航空故障电弧的识别

董伟, 张俊民, 桂美景, 李晨光

(北京航空航天大学自动化科学与电气工程学院, 北京 100083)

摘要: 针对航空故障电弧持续时间短、电流强度小、检测极为困难等特点, 提出在直流系统中基于小波包和 BP 神经网络的航空故障电弧识别方法。首先搭建串联和并联故障电弧实验平台, 采集线路正常和产生电弧情况下的电流信号; 对电流信号进行三层小波包分解, 根据求解到的总能量与总香农熵的比值, 确定最佳的小波包基函数; 利用每一频率段的能量与香农熵的比值确定航空故障电弧的特征频率段; 然后提取特征频率段的香农熵作为故障电弧的特征量; 最后利用 LM 算法优化的 BP 神经网络对故障电弧进行判别。结果表明, 故障电弧的识别率达到 95% 以上。

关键词: 直流航空故障电弧; 小波包分解; 故障频率段; 香农熵; BP 神经网络

DOI: 10.12067/ATEEE1801058 **文章编号:** 1003-3076(2018)11-0076-06 **中图分类号:** TM247

1 引言

航空故障电弧是严重影响飞机正常工作可靠性的因素之一, 其主要是由于电缆电气连接部位出现松动、接触不良或断裂等引起电路时通时断而产生的串联型故障电弧, 以及由于导线的绝缘出现刺穿、磨损、受潮、受污和老化等缺陷引起短路而产生的并联型故障电弧^[1]。由于电弧的阻抗特性, 在线路中产生串联故障电弧时, 线路电流减小, 传统的断路器无法对故障电弧进行有效的检测。因此, 对航空故障电弧的检测方法进行研究有重要的现实意义^[2]。

国内外学者对故障电弧检测方法的研究主要集中在电弧的物理特性和电弧电流电压波形的改变。物理特性主要是电弧的发光、发热、电磁辐射等; 电弧造成的电流波形的畸变, 电弧的不稳定燃烧对电路电流的影响是研究的重要出发点。文献[3]以磁流体动力学为基础, 借鉴现有的电弧模型, 综合考虑了电弧能量交换、辐射、传导等问题, 计算相关参数, 建立航空故障电弧的动态数学模型; 文献[4]搭建直流故障电弧模拟实验平台, 通过检测故障电弧产生的电磁辐射, 利用模极大值作为特征量, 对正常和故障情况进行判断; 文献[5]利用离散小波对串联故障电弧电流进行分解, 提取小波分解的能量作为

故障电弧的特征量, 对故障电弧进行识别。

在现有的文献中, 电弧的发生装置大都以电机带动两电极产生串联故障电弧, 这种方式产生的电弧过于理想化, 不能反映飞机上故障电弧的真实情况。另外, 这些文献大多只考虑串联故障电弧, 而没有考虑并联故障电弧, 这在实际应用中是不全面的。本文设计的串联故障电弧模拟发生装置在振动台的作用下产生电弧, 尽可能模拟真实情况, 使结果更具有代表性。同时考虑到并联故障电弧, 提出在小波包分解的基础上, 引入能量-香农熵比值的概念, 确定故障电弧的特征频率段并提取特征量, 最后利用 BP 神经网络进行故障识别。

2 电弧模拟装置及实验

2.1 电弧模拟装置

参照标准 AS6019^[6] 搭建串联和并联故障电弧实验平台, 模拟航空直流系统下的串联故障电弧和并联故障电弧。

串联故障电弧电路图及故障电弧发生装置示意图分别如图 1、图 2 所示。串联故障电弧发生装置的基本原理是在振动台的作用下, 松动的接线端子与螺栓之间会产生电弧。串联故障电弧的装置图如图 3 所示。通过实际的实验发现, 在振动情况下要

收稿日期: 2018-01-19
基金项目: 国家自然科学基金项目(51477004;51177005)
作者简介: 董伟(1993-), 男, 山东籍, 硕士研究生, 研究方向为故障电弧识别;
张俊民(1962-), 男, 北京籍, 副教授, 博士后, 研究方向为断路器、开关柜、电弧等技术。

想得到持续燃烧的电弧并不容易,因为只有当接线端子和固定螺栓之间产生足够大的相对位移时才能产生电弧。但当振动台振动频率提高以后,振动幅值会下降,相对位移也会减小。所以在每次实验前要尽可能地使松动的接线端子处于悬浮状态,不要和螺栓有固定的接触。




图1 串联故障电弧电路图
Fig.1 Circuit of series fault arc




图2 串联故障电弧发生装置示意图
Fig.2 Series fault arc generator schematic




图3 串联故障电弧装置
Fig.3 Series fault arc generator

并联故障电弧电路图及故障电弧发生装置示意图分别如图4、图5所示。并联故障电弧发生装置的基本原理是通过金属刀片切割两根导线,从而产生并联故障电弧。其主要模拟的是航空电缆由于振动摩擦或意外切割导致电缆导体裸露,从而出现电弧的情况。并联故障电弧的装置图如图6所示。

2.2 电弧模拟实验

实验中的电源电压为直流 28V,数据的采样频率为 25kHz,每个分析单元的数值点数为 250,即 10ms。串联故障电弧实验中的负载为 20Ω 电阻、电




图4 并联故障电弧电路图
Fig.4 Circuit of parallel arc fault




图5 并联故障电弧发生装置示意图
Fig.5 Parallel fault arc generator schematic



图6 并联故障电弧装置
Fig.6 Parallel fault arc generator

动机和节能灯,用来模拟飞机上的阻性负载、感性负载和容性负载。振动频率为 10Hz、15Hz、20Hz、30Hz 情况下每种负载类型采集 10 组数据,所以每种负载下共有 40 组数据。每一组实验都包括正常工作时的电流数据、带电弧工作时的电流数据、突然加载和突然减载时的电流数据,即每一组数据都包括四种不同情况下的电流信号。并联故障电弧实验中,为模拟线路的电阻,接入 5Ω 的电阻。其他情况与串联电弧实验相同。

图7、图8分别为线路产生串联和并联故障电弧时,连续采样 100ms 的电流波形。

3 故障特征分析方法

3.1 小波包分解

小波包分解是一种适合于非平稳信号的时频分析方法,它不仅能够有效分解信号的低频部分,并且对于高频部分也能进一步分解,可将信号分解到任




图7 串联故障电弧电流
Fig.7 Current of series arc fault




图8 并联故障电弧电流
Fig.8 Current of parallel arc fault

意细的频率段,满足对信号分析的要求^[7]。本文采用三层小波包分解,图9为小波包分解结构图。其中,节点 (m,n) 代表分解的第 m 层、第 $n+1$ 个节点, $(0,0)$ 代表所分析的原始信号。当采样频率为 f_s 时,第三层每个节点所对应的频率如表1所示。




图9 小波包3层分解结构示意图
Fig.9 Structure of three-layer wavelet packet decomposition

3.2 BP神经网络

神经网络具有很强的自我调整参数和模拟人类大脑学习的能力,能够以非常小的误差拟合任意非线性系统。神经网络由输入层、输出层和隐含层组

表1 节点与对应频率的关系

Tab.1 Relationship between node and corresponding frequency			
节点	频率	节点	频率
1	$0 \sim (1/16) f_s$	5	$(4/16) f_s \sim (5/16) f_s$
2	$(1/16) f_s \sim (2/16) f_s$	6	$(5/16) f_s \sim (6/16) f_s$
3	$(2/16) f_s \sim (3/16) f_s$	7	$(6/16) f_s \sim (7/16) f_s$
4	$(3/16) f_s \sim (4/16) f_s$	8	$(7/16) f_s \sim (8/16) f_s$

成,其中隐含层可以为一层也可以为多层^[8]。 n 个输入、 m 个输出、一层隐含层的神经网络结构如图10所示。其中 X 为输入, Y 为输出。




图10 BP神经网络结构图
Fig.10 Structure BP neural network

传统的BP神经网络在迭代学习过程中存在着易陷入局部极小值、收敛速度慢等缺点,故本文采用经Leverberg-Marquard(LM)算法优化的BP神经网络。LM算法是梯度下降法与高斯-牛顿法相结合的方法,相比于其他训练算法,其每一步迭代训练过程中的梯度变化幅度最大,缩短了训练时间,也不会使神经网络陷入局部极小点^[9]。

4 直流故障电弧特征量的提取

4.1 小波包基函数的选择

小波包分解中基函数的选择会影响分解的结果,不同的分析对象所适用的基函数也会不同,选择恰当的基函数对故障电弧特征的提取有很大帮助^[10]。在信号分析中常用的基函数有:haar、db5、db10、coif1、coif5、sym2、sym8^[11]。

小波包基函数的选择依据是能量-香农熵比值最大原则^[12]。使用不同的基波对采集的电流信号进行分解,求取总能量和总香农熵的比值,通过比较选取最大比值时的基函数。具体计算流程如下^[13]。

(1)第 n 个节点的能量值 $E(n)$:

$$E(n) = \sum_{i=1}^m |C_{n,i}|^2$$

(1)

式中, i 为第 n 个节点中的离散点序号; m 为第 n 个节点的离散点总个数; $C_{n,i}$ 为对应离散点的系数。

(2)第 n 个节点的香农熵 $S_{\text{entropy}}(n)$ 定义为:

$$S_{\text{entropy}}(n) = - \sum_{i=1}^m p_i \log_2 p_i \tag{2}$$

式中, p_i 的求解公式为:

$$p_i = \frac{|C_{n,i}|^2}{E(n)} \tag{3}$$

所以, $\sum_{i=1}^m p_i = 1$; 如果 $p_i = 0$, 则令 $p_i \log_2 p_i = 0$ 。

(3) j 层小波包分解的总能量和总香农熵的比值 ζ 定义为:

$$\zeta = \frac{\sum_{n=1}^{2^j} E(n)}{\sum_{n=1}^{2^j} S_{\text{entropy}}(n)} \tag{4}$$

随机选取每种负载下的一组数据,分别利用不同的基函数对信号进行三层小波包分解,根据式(1)~式(4)分别计算所选负载每种情况下的总能量-总香农熵比值,然后求取平均值。最终结果如表 2 所示。

表 2 总能量-总香农熵比值平均值

Tab. 2 Average of total energy to total Shannon entropy			
基函数	平均值	基函数	平均值
haar	118. 12	coif5	119. 83
db5	104. 81	sym2	113. 01
db10	98. 67	sym8	112. 56
coif1	123. 03		

由表 2 可以发现,当基函数为 coif1 时,所得的数值最大,所以选取 coif1 为小波包分解的基函数。

4.2 故障特征频率段的选取

正常工作状态下的电流和出现故障电弧状态下的电流并不是在所有的频率段都可以明显地区分出来,电弧造成的对电流波形的影响主要体现在高频部分。因此,适当故障特征频率段的选取会增加故障识别的正确率^[14]。

故障频率段的选取依据为各节点能量-香农熵的比值。利用式(2)和式(3)分别求出小波包分解节点的能量和香农熵,然后求解第 n 个节点能量-香农熵比值 $\zeta(n)$:

$$\zeta(n) = \frac{E(n)}{S_{\text{entropy}}(n)} \tag{5}$$

由于电弧会对电流造成畸变,所以高频段的分解系数会比较大,利用式(5)求解出高频段的 $\zeta(n)$

在故障情况下会相对较大。对故障电弧电流和正常电流分解后的各对应节点 $\zeta(n)$ 的比值求解,得到的值越大,说明两者之间在该频率段所包含的信息差别越大,则选取该频率段为故障频率段。

随机选取每种负载实验下的一组数据,选择 coif1 为基函数,进行三层小波包分解。根据式(5)求解出所选数据中电弧电流每一频率段 $\zeta_{\text{arc}}(n)$ 和正常状态下的电流每一频率段 $\zeta_{\text{nor}}(n)$,然后求取平均值,最后将正常工作状态下的电流和出现故障电弧状态下的电流对应频率段 $\zeta(n)$ 的平均值相比,设比值为 R ,最终计算结果如表 3 所示。

表 3 最终结果 R

Tab. 3 R of final calculation results			
节点	R	节点	R
1	3. 53	5	8. 88e05
2	6. 88e02	6	97. 91
3	3. 81e02	7	67. 96
4	1. 22e03	8	43. 47

由计算结果可以发现,节点 2~节点 5 的比值相对较大,故采用以上四个节点作为故障电弧的特征频率段。本文采样频率为 25kHz,即 f_s 为 25kHz,再根据表 1,可以得到故障特征频率段的范围为 1562. 5~7812. 5Hz。

4.3 故障特征量的选取

故障特征量选取得恰当与否,决定了故障识别的正确率。根据求解得到的故障频率段,选取相应频率段的香农熵作为故障特征,计算公式如式(2)所示。随机选取一组在 20Hz 的振动频率的数据为例,计算节点 2~节点 5 的香农熵。结果如表 4 所示。

表 4 故障频率段的香农熵

Tab. 4 Shannon entropy of fault frequency band					
实验序号	实验类别	香农熵			
		节点 2	节点 3	节点 4	节点 5
1	正常	4. 94	4. 89	4. 66	3. 94
	加载	0. 51	0. 48	0. 98	1. 26
	减载	4. 10	4. 82	4. 83	1. 94
	故障	2. 44	2. 79	2. 83	2. 71
2	正常	4. 85	5. 19	4. 88	5. 10
	加载	0. 44	0. 67	1. 03	1. 41
	减载	4. 82	4. 64	4. 71	4. 25
	故障	1. 75	2. 34	3. 10	2. 10
3	正常	4. 96	4. 46	4. 48	3. 86
	加载	0. 46	0. 65	1. 17	0. 80
	减载	4. 07	4. 91	4. 74	1. 50
	故障	2. 40	1. 91	1. 54	2. 56

由表 4 可以发现,只要电路处于正常的工作状态,在任何一种负载下,计算得到的特征量一直处于 3.8~5.0 范围内;当线路中存在电弧时,计算得到的特征量则处于 1.5~3.1 范围内。虽然线路中突然接入负载、减掉负载和出现故障电弧时都会使电流波形发生变化,但通过计算可以发现正常操作和出现故障电弧两种情况下,计算得到的香农熵的范围基本没有重叠,满足故障识别的要求。这为故障电弧较高的正确识别率提供了保障。

5 直流航空故障电弧的识别

对每一组数据进行小波包分解,求解节点 2~节点 5 的香农熵作为 BP 神经网络的输入,规定其输出在正常情况下为 1,存在电弧时的输出为 -1。所以使用的神经网络为四个输入,一个输出。将所有数据进行汇总,选取每种负载下 70% 的电流信号作为训练数据,其余 30% 的信号作为测试数据。最终得到的测试结果表明正确率超过 98%。

为了进一步验证该方法可以应用在直流故障电弧检测中,改变实验负载条件,再次采集数据作为测试数据。将电阻、电动机和节能灯并联,共同作为电路的负载,同时改变接入电阻的阻值为 10Ω。在串联条件下,每种振动频率下采集 10 组数据;在并联条件下,采集 10 组数据。每组数据包括正常和产生电弧时的电流数据。测试得到的结果如表 5 所示。

表 5 测试结果

Tab.5 Results of test		
实验类别	测试数据数量	误判数量
串联	20×4	3
并联	20	1

表 5 的测试结果表明,利用提取的故障特征香农熵结合 LM 算法优化的 BP 神经网络对故障电弧的识别率达到 95% 以上。出现误判的数据均是将正常工作判断为线路中存在电弧。经查看发现误判的四组数据中由于外界的干扰使得采集的电流出现波动,被误认为线路中存在电弧。所以,采集数据时要尽可能地避免外界干扰,同时增加训练样本,考虑多种情况下产生的故障电弧的情况,提高故障电弧的识别率。

6 结论

本文设计并搭建模拟直流 28V 航空供电系统的电弧发生装置,采集不同负载下正常工作和存在

故障电弧的电流。针对航空故障电弧检测极为困难的问题,提出了采用小波包分解提取故障特征,再结合 BP 神经网络进行判断的方法。首先根据能量-香农熵的比值确定故障电弧的特征频率段,再计算特征频率段的香农熵作为特征量,最终选取四个节点的香农熵作为判断依据。实验结果表明,本文方法区分正常工作和故障电弧的正确率达到 95% 以上,验证了该方法可以应用在直流故障电弧检测中。

参考文献 (References):

[1] 张俊民, 谢华博, 魏娟, 等 (Zhang Junmin, Xie Hua-bo, Wei Juan, et al.). 飞机电缆绝缘缺陷与故障的检测技术及分析 (Aircraft cable fault detection technology and its analysis) [J]. 航空维修与工程 (Aviation Maintenance & Engineering), 2008, (1): 26-29.

[2] 林方圆, 苏建徽, 赖纪东 (Lin Fangyuan, Su Jianhui, Lai Jidong). 光伏系统直流故障电弧识别方法研究 (Study on detection method of DC arc fault in PV systems) [J]. 电工电能新技术 (Advanced Technology of Electrical Engineering and Energy), 2015, 34 (12): 7-13.

[3] Zhang Junmin, Lu Chunrong, Guan Yonggang, et al. Thermodynamic properties and transport coefficients of air thermal plasmas mixed with ablated vapors of Cu and polytetrafluoroethylene [J]. Physics of Plasmas, 2015, 22 (10): 1-10.

[4] 陈照, 李奎, 张洋子, 等 (Chen Zhao, Li Kui, Zhang Yangzi, et al.). 基于电弧电磁辐射的故障电弧识别 (Arc fault detection based on electromagnetic radiation) [J]. 电工电能新技术 (Advanced Technology of Electrical Engineering and Energy), 2017, 36 (3): 70-74.

[5] Pan Q, Jovanovic S, Lezama J, et al. Discrete wavelet transform optimal parameters estimation for arc fault detection in low-voltage residential power networks [J]. Electric Power Systems Research, 2017, 143: 130-139.

[6] SAE AS6019, ARC fault circuit breaker (AFCB), aircraft, trip-free 28 VDC [S].

[7] Li W J, Li Y C. Arc fault detection based on wavelet packet [A]. International Conference on Machine Learning and Cybernetics [C]. Guangzhou, China, 2005. 3: 1783-1788.

[8] 韩旭, 王蒙 (Han Xu, Wang Meng). 基于遗传算法优化 BP 神经网络的故障电弧识别 (Arc fault identification based on BP neural network optimized by genetic algorithm) [J]. 测控技术 (Measurement & Control Technology), 2016, 35 (12): 21-25.

[9] 顾秀江, 姚竹亭 (Gu Xiujiang, Yao Zhuting). 基于改

- 进 BP 神经网络的模拟电路故障诊断 (Fault diagnosis of analog circuits based on improved BP network) [J]. 电子测试 (Electronic Test), 2011, (6): 8-11.
- [10] Ahmed F, Kandagal S B. Modal identification of aircraft wing coupled heave-pitch modes using wavelet packet decomposition and logarithmic decrement [J]. Procedia Engineering, 2016, 144: 435-443.
- [11] 崔芮华, 王绍敏, 刘磊 (Cui Ruihua, Wang Shaomin, Liu Biao). 基于小波包技术和熵理论的航空故障电弧特征频段研究 (Research on the characteristic frequency band of aviation arc fault based on the wavelet packet and entropy) [J]. 电气工程学报 (Journal of Electrical Engineering), 2017, 12 (1): 1-8.
- [12] Kankar P K, Sharma S C, Harsha S P. Fault diagnosis of rolling element bearing using cyclic autocorrelation and wavelet transform [J]. Neurocomputing, 2013, 110 (8): 9-17.
- [13] Kankar P K, Sharma S C, Harsha S P. Fault diagnosis of ball bearings using continuous wavelet transform [J]. Applied Soft Computing, 2011, 11 (2): 2300-2312.
- [14] 卢其威, 王涛, 李宗睿, 等 (Lu Qiwei, Wang Tao, Li Zongrui, et al.). 基于小波变换和奇异值分解的串联电弧故障检测方法 (Detection method of series arcing fault based on wavelet transform and singular value decomposition) [J]. 电工技术学报 (Transactions of China Electrotechnical Society), 2017, 32 (17): 208-217.

Identification of aviation arc fault based on wavelet packet decomposition

DONG Wei, ZHANG Jun-min, GUI Mei-jing, LI Chen-guang

(School of Automation Science and Electrical Engineering, Beihang University, Beijing 100083, China)

Abstract: Aiming at the characteristics of aviation arc fault, such as short duration, low current intensity and difficult detection, a method to identify aviation arc fault under DC power supply system based on wavelet packet and BP neural network is proposed. Firstly, an experimental platform simulating arc fault is built to collect the current signal of the line under different loads. Then three-layer wavelet packet decomposition method is used to analyze the current signal. A criterial maximum total energy to total Shannon entropy ratio is used to select base wavelet. The ratio of energy to Shannon entropy is used to determine the characteristic frequency band of arc fault, and Shannon entropy is extracted as the characteristic of arc fault. Finally, the BP neural network optimized by Leverberg-Marquard algorithm is used to identify the arc fault. The results show that identification accuracy of arc fault is more than 95%.

Key words: DC aviation arc fault; wavelet packet decomposition; fault frequency band; Shannon entropy; BP neural network