

DOI: 10.19650/j.cnki.cjsi.J2007245

光伏发电系统直流串联微弱故障电弧检测方法研究*

唐圣学^{1,2}, 刁旭东^{1,2}, 陈丽^{1,2}, 张继欣^{1,2}, 姚芳^{1,2}

(1. 河北工业大学 省部共建电工装备可靠性与智能化国家重点实验室 天津 300130;

2. 河北工业大学 河北省电磁场与电器可靠性重点实验室 天津 300130)

摘要:光伏发电系统直流故障电弧因随机性强、信号微弱、容易受负载突变影响而难以准确检测。根据光伏电池 $U-I$ 输出特性,文中分析光伏发电系统直流串联微弱故障电弧产生机理,通过搭建光伏发电系统故障电弧模拟实验平台,分析了微弱直流串联故障电弧信号特性;进而提出了一种基于电流小波能量熵特征的检测直流串联微弱故障电弧的方法。该方法先计算电流信号脉冲因子,并利用阈值比较法来检测故障电弧。在此基础上,进一步计算电流小波能量熵特征,并采用极限学习机(ELM)辨识微弱故障电弧。实验结果表明:所提方法不仅能检测强直流故障电弧,还能检测微弱直流故障电弧,且平均辨识率高达98%。

关键词:光伏系统;直流电弧;故障电弧;小波能量熵特征

中图分类号: TM501 TH86 **文献标识码:** A **国家标准学科分类代码:** 470.40

Study on detection method of weak series DC fault arc in PV power generation systems

Tang Shengxue^{1,2}, Diao Xudong^{1,2}, Chen Li^{1,2}, Zhang Jixin^{1,2}, Yao Fang^{1,2}

(1. State Key Laboratory of Reliability and Intelligence of Electrical Equipment, Hebei University of Technology, Tianjin 300130, China; 2. Key Laboratory of Electromagnetic Field and Electrical Apparatus Reliability of Hebei Province, Hebei University of Technology, Tianjin 300130, China)

Abstract: Fault arc in photovoltaic power generation system is difficult to accurately detect due to strong randomness, weak signal, and easy to be affected by load sudden change. According to the $U-I$ output characteristics of photovoltaic cells, this paper analyzes the generation mechanism of DC series weak fault arc in photovoltaic power generation system, and analyzes the characteristics of weak DC series fault arc signal by building a photovoltaic power generation system fault arc simulation experimental platform, and then a method to detect weak DC series fault arc based on the wavelet energy entropy features of current signal is proposed. The proposed method firstly calculates the current pulse factor, which are used to detect the fault arc with threshold comparison method. On this basis, the current wavelet energy entropy features are calculated to identify weak fault arc based on extreme learning machine (ELM). The experimental results show that the proposed method can not only detect strong DC fault arc, but also detect weak DC fault arc with high average identification rate 98%.

Keywords: PV power generation system; DC arc; fault arc; wavelet energy entropy features

0 引言

光伏发电系统中,直流故障电弧严重影响着系统正常运行。根据故障电弧发生形式,故障电弧可分为串联故障电弧、并联故障电弧和接地故障电弧^[1]。串联故障

电弧常因回路电流、电压变化较小,而难以有效检测,影响系统可靠性。

目前,直流故障电弧检测方法主要有两类:一类是利用电弧放电时的弧光、发热、噪声以及电磁辐射等特性实现故障电弧检测^[2-4],具有精度高优点,但是成本也高;另一类是利用故障电弧信号时域、频域特征或者时频域特

收稿日期:2020-12-15 Received Date: 2020-12-15

* 基金项目:河北省自然科学基金面上项目(E2019202481)、河北省自然科学基金重点基金(E2017202284)项目资助

征进行检测^[5-14],具有成本低优点。目前,关于光伏发电系统直流故障电弧检测识别的方法主要有:文献[6]利用阈值法,通过比较特定时间长度的电弧电流变化率来检测电弧故障。文献[9]研究了直流电弧回路电流的变化规律,提出了一种基于电源电压的故障电弧检测方法。文献[10-11]研究了基于小波变换、傅里叶分析等的直流电弧故障检测方法。文献[12-18]研究了支持向量机、神经网络等算法在直流故障电弧检测中的应用。但是上述方法没有考虑光伏发电故障电弧信号微弱性。

光伏发电系统直流侧故障电弧导致的信号变化有时会比较微弱,导致故障电弧难以检测。对于此问题,文献[19]采用小波奇异值特征来检测微弱直流故障,提升了故障电弧检测效果,但是没有分析光伏电源特性对电弧的影响,没有解释产生的机理。并且故障电弧奇异点与负载突变奇异点、噪声奇异点难以区别,尤其是微弱奇异点数量多、干扰大。

针对光伏发电系统直流故障电弧检测问题,本文从光伏电源 $U-I$ 特性出发,分析了微弱直流故障电弧产生机理,通过搭建光伏直流故障电弧模拟实验平台,分析电弧特性,进而提出了一种微弱直流故障电弧检测方法。

1 串联微弱故障电弧产生的原因

1.1 理论分析

图1给出了光伏发电系统直流故障电弧的等效电路原理图,其中 R_{arc} 为电弧电阻、 R 为线路负载、 I_h 为回路电流、 U 为光伏电源。




图1 直流故障电弧电路

Fig. 1 DC fault arc circuit

电路稳态时的工作原理如图2所示,图2中负载线由负载和电弧等效电阻 $R_0=R+R_{arc}$ 。由图2可见,光伏发电系统输出特性曲线可分为两段,即恒流区和非恒流区。在恒流区,光伏电池输出电流基本保持不变;在非恒流区,光伏电池输出电流随工作点改变变化明显。

通常,故障电弧可用一个非线性可变电阻来简化建模。当电弧电极间隙固定、电弧稳定燃烧时,电弧阻值会围绕一个恒定值附近变化,并引起回路等效总电阻 $R_{总}$ 变化、回路电压/电流状态变化。




图2 光伏电源工作点示意图

Fig. 2 Working point diagram of photovoltaic power supply

由图2可知,当调整负载使光伏电池电源正常工作于 A_1 点时,在一定范围内(B点左侧)光伏电源的输出特性等效于一个恒流源,在本文中称为恒流源区域。在 A_1 点触发电弧后,电弧电阻 R_{arc} 发生,使电源外部回路总电阻 $R_0=R_{arc}+R$ 增大,相当于负载电阻变大,负载所确定的直线斜率变小,对应图1中相当于直线 L_1 顺时针旋转到 L_1' ,对应光伏电源工作点由 A_1 点向右移动到 A_2 点。由于电弧持续燃烧所需要的电压不高,所以 A_1 点和 A_2 点距离较近,两者同处于恒流源区域,所以电弧发生前后回路电流没有突变。同时,在电弧发生后,如果负载电阻不变,则负载电阻上的电压变化也不大。这正是直流故障电弧信号比较微弱的原因。

当调整负载使光伏电源正常工作于 C_1 点时,相对于 A_1 点,属于非恒流源区域(直线 L_2 的右侧),显然此时光伏电源输出电流随工作点变化比较明显。当直流故障电弧发生后,电源外部回路串联了电弧电阻 R_{arc} ,使输出总 $R_0=R_{arc}+R$ 增大,外部电阻 R_0 所确定的直线斜率变小,对应图中直线 L_3 顺时针旋转到直线 L_3' 。即电弧发生后,工作点由 C_1 点转变到了 C_2 点。可以看出,相较于 A_1 点移动到 A_2 点的过程,此时电流改变较明显,负载电压和电量变化明显,电弧容易被检测。

综上所述可以得出,当电弧发生在 C_1 点附近时,光伏电源输出电流变化比较大,故障电弧易于检测;当电弧发生在 A_1 点附近即恒流源区域时,相对于 C_1 点来说,电流变化并不明显,直流故障电弧信号比较微弱,不利于故障电弧检测。

1.2 故障电弧发生实验验证

为了验证上述分析结论,针对图1所示的光伏发电系统电路,文中搭建了图3所示的实验平台。平台由光伏电源、电弧发生器、负载、示波器组成,其中光伏电源由8块型号为SL30CE-18P的光伏电池板串联组成,光伏电池板与光伏电源参数如表1所示。

表1中主要给出了开路电压、短路电流和标准测试条件下的最大功率点处的功率和电压。




图 3 光伏发电系统图

Fig. 3 Photovoltaic power generation system diagram

表 1 光伏电源参数

Table 1 Parameters of photovoltaic power supply

参数	光伏电池板 (SL30CE-18P)	光伏电源 (8 个串联)
P_{max}/W	30	240
V_{oc}/V	21.82	174.56
I_{sc}/A	1.79	1.79
V_{mpp}/V	17.8	142.4
I_{mpp}/A	1.68	1.68

电弧发生器参考 UL1699B 标准而搭建,其结构如图 4 所示。电弧发生装置主要由静止电极、活动电极、侧面调节器、滑块、螺旋杆和固定底座等组成。静止电极选用一根直径为 6 mm 的平头铜棒,活动电极选用一根 6 mm 的尖头铜棒,两个电极分别被固定在绝缘块上,通过侧面调节器调节两者之间的距离。




图 4 电弧发生器

Fig. 4 Arc generator

数据采集和分析采用 Tektronix DPO5034B 款混合信号示波器实现,采集卡具有多个 8 位高速高精度 AD 采样通道,最高采样率可达 50 MS/s,实验中采样频率为 500 kHz,采样时间为 200 ms,采样时间长度足以观测到电弧发生到稳定时的信息。数据由电流探头和电压探头采集负载上的电压和电流采集。

实验过程中采用拉弧法产生电弧。首先使电弧发生器中两电极相互接触,观察示波器产生稳定电流;然后缓慢调节电弧发生器的调节器,使两电极相互分离并产生稳定燃烧的电弧,同时利用示波器对数据进行采集及保存。

利用实验平台,在光照 73 klx、温度 30℃ 和光照 26 klx、温度 20℃ 的环境条件下,测试光伏电池的 U-I 特性曲线如图 5 所示。由图 5 可见,光伏电池 U-I 特性曲线可分为恒流区和可变电阻区两部分,与前面理论分析相符。对第一种测试条件下进行具体动态电阻分析,结果如表 2 所示。




图 5 光伏电池测试曲线

Fig. 5 Photovoltaic cell test curve

由表 2 可见,根据动态电阻特性可知,Ⅰ、Ⅲ为恒流区,Ⅱ、Ⅳ为非恒流区,恒流区电阻明显大于非恒流区。

表 2 光伏电池动态电阻测试值

Table 2 Dynamic resistance test value of photovoltaic cell

	U/V	$\Delta U/V$	I/A	$\Delta I/A$	$\Delta r/k\Omega$
Ⅰ	6.78	70.02	1.473	0.006	11.67
	76.8		1.467		
Ⅱ	117.6	0.40	0.288	0.029	0.014
	118		0.259		
Ⅲ	2.85	32.45	0.627	0.006	5.4
	35.3		0.621		
Ⅳ	110.1	4.4	0.275	0.025	0.176
	114.5		0.250		

通过调节负载电阻,使实验电路分别工作于光伏电池恒流区和非恒流区,然后进行拉弧电弧实验,实验波形如图 6 和 7 所示,其中图 6 为恒流区电弧波形,图 7 为非恒流区电弧波形。

由图 6 可知,恒流区微弱故障电弧发生稳定前后,存




图6 恒流区典型电弧电流波形

Fig. 6 Typical arc current waveform in constant current region




图7 非恒流区典型电弧电流波形

Fig. 7 Typical arc current waveform in non constant current region

在均值电流 0.062 A 的变化量。计算得故障前电流方差为 0.18×10^{-3} , 故障后方差为 0.22×10^{-3} 。显然, 电流变化不明显。

由图 7 可知, 非恒流区强故障电弧发生稳定前后, 存在均值电流 0.23 A 的变化量。计算得故障前电流方差为 0.12×10^{-3} , 故障后方差为 0.48×10^{-3} 。显然, 电流变化较为明显。

对比图 6 和 7 可以发现: 恒流区电流变化的幅度的波动均小于非恒流区, 故恒流区微弱故障电弧比非恒流区强故障电弧难以检测。

图 6 和 7 需要说明的是: 电弧发生时间非常短, 非恒流区电流瞬时变化跟负载引起变化非常类似, 容易造成混淆。

综上分析, 基于恒流区和非恒流区电流方差等特征, 可通过对光伏发电系统直流串联故障电弧的电流进行时频域分析, 实现对串联电弧故障的识别。因此, 文中提出一种基于电流时频域特征的电弧检测方法, 该方法可以有效对光伏发电系统串联微弱电弧进行检测。

2 基于电流时频域特征的微弱电弧检测方法

2.1 时域特征分析与提取

对于非恒流区故障电弧, 电流变化较大, 文中采用时域特征进行检查, 采用的时域特征主要有电流方差、脉冲因子、峭度因子等。通过分析比较正常电流及故障电弧电流的这些时域特征, 确定光伏系统电池非恒流区串联故障电弧的发生。

方差可表征变量离散程度。根据前面分析可知, 直流故障电弧发生后输出电流会发生突变, 无论是恒流区还是非恒流区, 回路电流/电压波动加剧, 肯定会导致其方差 σ^2 变大。方差其计算公式为:

$$\sigma^2 = \frac{\sum (X - \mu)^2}{N} \quad (1)$$

式中: $x_i (i=1, \dots, N)$ 为采样点数值; μ 为平均值; N 为总体例数。

脉冲因子、峭度因子可表示波形变化的平缓程度的, 可作为检测信号中有无冲击/突变的无量纲特征。脉冲因子、峭度因子计算公式分别为:

脉冲因子:

$$I_M = \frac{X_p}{\bar{x}} \quad (2)$$

峭度因子:

$$K = \frac{\mu_4}{\sigma^4} \quad (3)$$

其中, X_p 为峰值; $\bar{x}$ 为数学期望; μ_4 为四阶中心矩。

为了说明上述特征在故障电弧发生前后的变化, 下面选取非恒流区电流 0.2 s 波形进行分析, 此处选取 0.2 s 时间数据为了更清楚反映电弧暂态变化情况。非恒流区串联故障电弧发生时电流方差、峭度因子波形分别如图 8、9 所示。图中电流波形为灰色线, 方差、峭度因子波形为黑色线。

对比图 8、9 可知, 在非恒流区发生串联故障电弧时, 电流方差、峭度因子状态波动剧烈。由图 8 和 9 可知, 方差和峭度因子在电弧发生期间变化非常明显, 但电弧稳定后数值较小, 因此二者都不宜单独作为故障电弧检查特征。

图 10 给出了恒流区和非恒流区电弧发生前后及变




图8 电流与电流方差曲线

Fig. 8 Current and current variance curve




图9 电流与电流峭度因子曲线

Fig. 9 Current and current kurtosis factor curve

负载情况下脉冲因子的变化波形。图10中电流波形为灰色线,脉冲因子波形为黑色线。由图10(a)和(b)可知,电弧发生期间及其稳定后,无论是恒流区和非恒流区情况,脉冲因子与正常状态时相比,变化明显;由图10(c)可以看出,负载突变时,电流幅值明显下降,但脉冲因子变化幅度很小。

脉冲因子在电弧发生瞬间幅值很大,可用于判断故障电弧是否发生。对于文中实验平台,经过多组数据分析,可将脉冲因子阈值设为1.13。由图10(a)和(b)可看出,脉冲因子都超过了阈值,说明直流电弧故障已经发生。由图10(c)可看出,负载突变时,脉冲因子变化幅度很小,远小于阈值,故不会造成误判。

电弧稳定后,非恒流区故障电弧脉冲因子变化数值较大,仍可作为故障电弧检测特征。然而,恒流区电流脉冲因子数值较小,与正常情况很接近,此时仅根据脉冲因子难以判定是否存在故障电弧。因此,脉冲因子可作为检测电弧初步判据,对于恒流区微弱电弧还需要结合其它特征进行检测,如其它时频特征。

2.2 时频域特征分析与提取

除了负载变化干扰外,对于微弱直流故障电弧而言,电弧检测还容易受到噪声等因素干扰,导致误判断。熵是信息不确定性、随机性的一种度量。前面实验分析可知,虽然恒流区电弧发生前后信号波形波动




图10 电流与电流脉冲因子曲线

Fig. 10 Current and current pulse factor curve

大小幅度相差不大,但波形疏密分布等特征区别较大。即直流故障电弧发生后,因电弧非线性特性和光伏电池的近恒流特性,会导致信号不同尺度下的能量分布特性变化。

为了说明直流电弧信号的时频特性,文中选用小波能量熵特征进行分析。小波能量熵将熵和小波变换结合起来,能很好的度量电弧发生前后各尺度下能量特征分布,因此可采用小波能量熵来检测微弱直流故障电弧。

电弧测试信号 $X = \{x_1, x_2, \dots, x_n\}$ 经过小波分解后,第 j 子带的系数为 $c_j(k)$, $j \in (1, 2, \dots, N)$, $k \in (1, 2, \dots, K)$, N 为子带数, K 为系数个数,那么第 j 子带的能量为:

$$E_j = \sum_k c_j^2(k) \quad (4)$$

对电弧信号进行 m 层树形小波分解,令矢量 $E = (E_1, E_2, \dots, E_m)$ 为 2^m 个子带的能量,那么 E 表征了电弧能量分布特征。

令能量 E_T 等于各个子带分能量 E_j 之和,设

$p_j = E_j / E_T$, 则有 $\sum_j p_j = 1$ 。于是小波能量熵 H 为:

$$H(X) = - \sum_{i=1}^N p_i \ln(p_i) \quad (5)$$

式(5)所示的小波能量熵度量了电弧信号在整个频带的能量分布特征。

利用图3所示实验平台,通过随机模拟直流故障电弧发生位置和负载变化,文中测试了上述微弱直流故障电弧的时频特征。为了充分观测暂态信息,文中数据时间长度为5 ms,采样频率为500 kHz,小波函数采用db4,小波分解为4层。利用MATLAB平台 wavedec 函数完成分解,分解后高低频信号频带如图11所示,图11中 cL1、cH1 分别为第一层分解后的低频和低频信号,其他层的分解类同。






图 11 小波分解示意图

Fig. 11 Schematic diagram of wavelet decomposition

图12和13分别给出了电流恒流区正常状态和电弧状态下小波分解后的低频和高频信号,图14和15则分别给出了非恒流区正常状态和电弧状态下的低频和高频信号,这些图14、15中 S 为原始信号。分解信号为去除均值后的分解信号,这样可充分利用熵特征来获取故障电弧动态信息。




(a) Current low frequency signal




(b) Current high frequency signal

图 12 恒流区正常状态电流分解信号波形

Fig. 12 Current decomposition signal waveform of normal state in constant current region



(a) Current low frequency signal



(b) Current high frequency signal

图 13 恒流区电弧电流分解信号波形

Fig. 13 Decomposition signal waveform of arc current in constant current region




图 14 非恒流区正常工作电流分解信号波形
Fig. 14 Decomposition signal waveform of normal working current in non constant current region

上述实验电流小波分解后求得的典型小波能量熵值如表 3 所示。

表 3 典型电流小波能量熵值
Table 3 Wavelet energy entropy of typical current

	恒流区		非恒流区	
	正常	故障	正常	故障
S	2.031 6	2.396 4	2.253 1	2.977 5
cL1	3.052 9	2.622 6	2.553 9	3.214 1
cL2	3.342 1	2.830 2	2.816 3	3.348 2
cL3	3.601 2	3.015 5	3.057 8	3.300 4
cL4	3.671 7	3.157 6	3.302 3	3.667 1
cH1	1.291 7	1.861 1	1.109 2	2.228 4
cH2	1.422 1	2.193 1	1.335 1	2.696 0
cH3	2.118 0	2.404 6	1.803 2	2.986 9
cH4	2.591 7	2.770 4	2.547 9	3.320 3




图 15 非恒流区电弧电流分解信号波形
Fig. 15 Decomposition signal waveform of arc current in non constant current region

从表 3 可见,对于低频分量而言,恒流区正常状态下其能量熵值大于电弧故障分量能量熵值,非恒流区正常状态下能量熵值小于电弧故障分量能量熵值;对于高频分量能量熵值而言,无论是恒流区还是非恒流区,故障分量能量熵值明显的大于正常状态能量熵值,故可用小波能量熵值作为故障特征来辨识分类。本文将小波分解低频分量和高频分量能量熵值作为故障特征组成特征向量,进而采用极限学习机实现电弧故障辨识。

2.3 极限学习机

极限学习机(extreme learning machine, ELM) 是一种单隐含层前馈神经网络,是一种高效的机器学习分类与回归算法。与传统的神经网络不同,ELM 不需要进行反复迭代来调整各层之间的连接权值与阈值,具有学习速度快、精度高、结构简单等优点。

极限学习机输入层神经元个数等于输入特征变量维数 n ,隐含层由 L 个神经元组成,输出层神经元个数等于

故障种类数 m 。假设共有 Q 个训练样本,训练集输入矩阵和输出矩阵分别为 $\mathbf{X}_{n \times Q}$ 、 $\mathbf{Y}_{m \times Q}$,那么分类器输入输出关系为:

$$\mathbf{Y}_{m \times Q} = \sum_{i=1}^l \beta_{im} g(w_i x_j + b_i) \quad (6)$$

式中: w_i 、 x_j ($j = 1, 2, \dots, Q$) 分别为输入层和隐含层之间的连接权值 $\mathbf{W}_{l \times n}$ 、隐含层与输出层之间的连接权值 $\mathbf{X}_{n \times Q}$ 的列向量, b_i 为隐含层神经元阈值, $g(x)$ 为激活函数。将式(5)表示为 $\mathbf{T}^T = \mathbf{H}\boldsymbol{\beta}$, 其中 $\mathbf{Y}^T$ 为输出矩阵 $\mathbf{Y}$ 的转置, $\mathbf{H}$ 为隐含层输出矩阵, 那么 $\boldsymbol{\beta} = \mathbf{H}^{-1} \mathbf{T}^T$ [20-22]。

2.4 直流电弧故障检测流程

文中所提光伏发电系统直流故障电弧检测识别方法利用 2 个 5 ms 数据来辨识故障电弧,具体步骤为:

1) 采集第 1 个 5 ms 电流数据,并计算电流脉冲因子 I_{M1} ; 然后比较 I_{M1} 与阈值 $I_{M,th}$ (文中实验阈值大小取值为 1.13) 大小关系,如果 $I_{M1} < I_{M,th}$ 满足,则电路状态没有突变,电路正常;否则,判定电路状态发生了变化,此时可能是发生故障电弧或负载突变或正常开关电弧,需要进一步确认,即进行步骤 2)。

2) 采集第 2 个 5 ms 电流数据,并计算电流脉冲因子 I_{M2} ; 同理,比较 I_{M2} 与阈值 $I_{M,th}$, 如果 $I_{M2} < I_{M,th}$ 满足,则判定是负载突变或者正常开关电弧,并回到步骤 1); 否则,判定发生了故障电弧,并进行第 3 步。通过连续检测 2 个 5 ms 周期,可区分正常电弧和故障电弧。

3) 计算小波能量熵特征,利用极限学习机输出判断故障电弧是微弱故障电弧还是强故障电弧。

3 微弱故障电弧检测实验

利用图 3 实验平台,随机改变电极间距和负载,构造不同工作点下电池输出电流 5 ms 数据库,包括微弱故障电弧和强故障电弧状态数据各 150 个,并提取故障特征向量组成样本集,共计可得 300 组样本特征数据集。随机选取 4/5 作为 ELM 学习机训练集,其余 1/5 作为测试集。考虑分类精度和诊断时间,经反复尝试,当隐含层神经元个数为 300 时,分类精度较高且用时较少。

在确定电弧故障发生情况下,图 16 给出了 60 个测试样本的测试结果,图 16 中 1 代表微弱故障电弧,2 代表非微弱故障电弧,圆圈和点分别代表真实类别和 ELM 辨识类别,圆圈和点重叠代表辨识正确。由图 16 可知,60 个测试样本中 59 个预测正确,出现错误的原因主要为实验测得训练集样本数量不够多,存在一定偏差。预测正确率为 98.3%,说明辨识效果较好。

在个人 PC 机、主频 2.2 G、内存 8 G、MATLAB 平台上试验,图 17 给出了 ELM 辨识的 30 次随机测试的结果。




图 16 测试集故障电弧辨识结果比较

Fig. 16 Comparison of fault arc identification results of test set




图 17 30 次随机测试结果

Fig. 17 Results of thirty random tests of ELM

果。由图 17 可知,30 次测试中,12 次精度为 100%,16 次为 98.3%,2 次为 96.7%,平均精度为 98.9%,辨识效果较好。

为了说明文中小波能量熵+ELM 方法的辨识效果,利用 MATLAB 神经网络工具箱、ELM 函数库和 Libsvm 函数箱等方法,表 4 给出了小波能量熵+ELM 辨识与小波+BPNN(BP 神经网络)、小波+ELM、FFT+ELM、小波能量熵+BPNN、小波能量熵+SVM(支持向量机)的测试辨识结果。其中,小波变换采用 db4 小波三层分解后系数均值和标准差作为特征值;BP 神经网络层数为 3,隐层神经元个数为 50;SVM 核函数为径向基函数。为了减少算法不确定影响和便于对比,表 4 中测试数据为 10 次随机测试效果平均值。由表 4 可见,与其它方法相比,小波能量熵+ELM 在训练精度、测试精度效果都较优,且辨识时间少。

表 4 6 种辨识方法测试性能对比
Table 4 Comparison of test performances among
six identification methods

辨识方法	训练数	测试数	训练精 度/%	测试精 度/%	辨识时 间/s
小波+BP	240	60	94.6	93.3	0.025
小波+ELM	240	60	97.2	96.2	0.004
FFT+ELM	240	60	94.2	93.0	0.004
小波能量熵+BP	240	60	95.4	94.6	0.026
小波能量熵+SVM	240	60	97.3	96.4	0.015
小波能量熵+ELM	240	60	99.8	98.8	0.003

此外,表 5 给出了 5 个典型的测试样本数据及其测试结果。结合图 16 和表 4 可知,本文采用方法诊断准确率高,性能良好。

表 5 ELM 测试结果
Table 5 ELM test results

	样本 1	样本 2	样本 3	样本 4	样本 5
编号	1	18	32	44	56
cL1	2.784 6	1.955 6	1.668 4	2.238 7	2.892 9
cL2	2.957 9	2.428 7	1.738 6	2.415 6	3.144 5
cL3	3.128 8	2.481 8	1.820 2	2.538 4	3.323 1
cL4	3.159 2	2.359 5	1.875 6	2.631 7	3.288 5
cH1	1.697 4	1.893 9	1.292 6	1.207 8	2.126 1
cH2	1.965 3	2.150 5	1.737 6	1.454 9	2.652 4
cH3	2.493 3	2.457 6	1.942 5	2.040 0	3.025 6
cH4	2.823 0	2.748 7	2.804 5	2.757 0	3.049 5
ELM 输出	强电弧	强电弧	弱电弧	弱电弧	弱电弧
结论	正确	正确	正确	正确	正确

4 结 论

本文针对光伏发电系统直流串联故障电弧检测问题,通过理论与实验分析,指出了微弱故障电弧产生的机理,从电弧电流信号找到了故障电弧检测特征,提升了微弱故障电弧检测能力,进而提出了一种微弱直流故障电弧检测方法。所提方法不仅能有效判别是否发生直流故障电弧,还能检测出微弱故障电弧,具有检测速度快,抗干扰性强,效率高的优点,为光伏发电系统直流故障电弧的检测提供了一种新的可借鉴思路。

参考文献

[1] 杨凯,张认成,杨建红,等. 基于分形维数和支持向量机的串联电弧故障诊断方法[J]. 电工技术学报, 2016, 31(2): 70-77.
YANG K, ZHANG R CH, YANG J H, et al. Series arc fault diagnostic method based on fractal dimension and support vector machine [J]. Transactions of China Electro-technical Society, 2016, 31(2): 70-77.

[2] 蔡彬,陈德桂,吴锐,等. 开关柜内部故障电弧的在线检测和保护装置[J]. 电工技术学报, 2005(10): 87-91.
CAI B, CHEN D G, WU R, et al. Online detecting and protection system for internal faults arc in switchgear[J]. Transactions of China Electro-technical Society, 2005(10): 87-91.

[3] 李奎,陈照,张洋子,等. 基于聚类分析和电磁辐射信号的电弧故障识别[J]. 电机与控制学报, 2018, 22(5): 94-101.
LI K, CHEN ZH, ZHANG Y Z, et al. Arc fault detection based on cluster analysis and electromagnetic radiation[J]. Electric Machines and Control, 2018, 22(5): 94-101.

[4] 王尧,张彦风,牛峰,等. 光伏直流电弧电磁辐射特性分析与测量方法[J]. 电工技术学报, 2019, 34(14): 2913-2921.
WANG Y, ZHANG Y F, NIU F, et al. Characterization and measurement method of DC arc electromagnetic radiation for photovoltaic systems [J]. Transactions of China Electro-technical Society, 2019, 34 (14): 2913-2921.

[5] 张冠英,张晓亮,刘华,等. 低压系统串联故障电弧在线检测方法[J]. 电工技术学报, 2016, 31(8): 109-115.
ZHANG G Y, ZHANG X L, LIU H, et al. Online detection method for series arcing fault in low voltage system [J]. Transactions of China Electro-technical Society, 2016, 31(8): 109-115.


[6] 张冠英,李长伟,赵远,等. 基于周期均值变化率的直流故障电弧检测[J]. 电气工程学报, 2016, 11(9): 44-47.
ZHANG G Y, LI CH W, ZHAO Y, et al. Series DC arcing fault detection method based on rate of cycle mean[J]. Journal Of Electrical Engineering, 2016,

- 11(9): 44-47.
- [7] 马征, 张国钢, 柯春俊. 一种基于高频电流频谱分析的故障电弧检测方法[J]. 电器与能效管理技术, 2010(9): 10-12.
- MA ZH, ZHANG G G, KE CH J. A method of fault arc detection based on spectral analysis of high-frequency current [J]. Electrical & Energy Management Technology, 2010(9): 10-12.
- [8] 赵景波, 唐勇伟, 张磊. 基于改进小波变换的故障电弧检测方法的研究[J]. 电机与控制学报, 2016, 20(2): 90-97.
- ZHAO J B, TANG Y W, ZHANG L. Improved wavelet transform algorithm of anti spectrum aliasing based on adding odd extraction before a node [J]. Electric Machines and Control, 2016, 20(2): 90-97.
- [9] 刘源, 汲胜昌, 祝令瑜, 等. 直流电源系统中直流电弧特性及其检测方法研究[J]. 高压电器, 2015, 51(2): 24-29.
- LIU Y, JI SH CH, ZHU L Y, et al. Characteristics and detection of DC arc in DC power system [J]. High Voltage Apparatus, 2015, 51(2): 24-29.
- [10] 卢其威, 王涛, 李宗睿, 等. 基于小波变换和奇异值分解的串联电弧故障检测方法[J]. 电工技术学报, 2017, 32(17): 208-217.
- LU Q W, WANG T, LI Z R, et al. Detection method of series arcing fault based on wavelet [J]. Transactions of China Electro-technical Society, 2017, 32 (17): 208-217.
- [11] CHEN S L, LI X W, MENG Y, et al. Wavelet-based protection strategy for series arc faults interfered by multicomponent noise signals in grid-connected photovoltaic systems [J]. Solar Energy, 2019, 183: 327-336.
- [12] WANG Z, BALOG R S. Arc fault and flash detection in photovoltaic systems using wavelet transform and support vector machines [C]. 2016 IEEE 43rd Photovoltaic Specialists Conference (PVSC), 2016: 3275-3280.
- [13] LE V, YAO X, MILLER C, et al. Series DC arc fault detection based on ensemble machine learning [J]. IEEE Transactions on Power Electronics, 2020, 35 (8): 7826-7839.
- [14] QU N, ZUO J, CHEN J, et al. Series arc fault detection of indoor power distribution system based on LVQ-NN and PSO-SVM [J]. IEEE Access, 2019 (7): 184020-184028.
- [15] TELFORD R D, GALLOWAY S, STEPHEN B, et al. Diagnosis of series DC arc faults—A machine learning approach [J]. IEEE Transactions on Industrial Informatics, 2017, 13(4): 1598-1609.
- [16] 张冠英, 张艳娇, 赵远, 等. 基于高斯过程分类的串联直流电弧故障检测[J]. 高压电器, 2020, 56(4): 1-7.
- ZHANG G Y, ZHANG Y J, ZHAO Y, et al. Detection method of series DC arc fault based on gaussian process classification [J]. High Voltage Apparatus, 2020, 56(4): 1-7.
- [17] 焦治杰, 李腾, 王莉娜, 等. 基于卷积神经网络的光伏系统直流串联电弧故障检测[J]. 电工电能新技术, 2019, 38(7): 29-34.
- JIAO ZH J, LI T, WANG L N, et al. DC series arc-fault detection of photovoltaic system based on convolutional neural network [J]. Advanced Technology of Electrical Engineering and Energy, 2019, 38(7): 29-34.
- [18] 吴春华, 徐文新, 李智华, 等. 光伏系统直流电弧故障检测方法及其抗干扰研究[J]. 中国电机工程学报, 2018, 38(12): 3546-3555.
- WU CH H, XU W X, LI ZH H, et al. Study on detection method and its anti-interference of DC arc fault for photovoltaic system [J]. Proceedings of the CSEE, 2018, 38(12): 3546-3555.
- [19] 吴春华, 黄宵宵, 李智华, 等. 光伏系统直流微弱电弧信号检测研究[J]. 中国电机工程学报, 2019, 39(20): 6025-6033.
- WU CH H, HUANG X X, LI ZH H, et al. Research on DC weak arc signal detection in photovoltaic system [J]. Proceedings of the CSEE, 2019, 39(20): 6025-6033.
- [20] HUANG G, HUANG G B, SONG S, et al. Trends in extreme learning machines: A review [J]. Neural Networks, 2015, 61: 32-48.
- [21] 张淑清, 苑世钰, 姚玉永, 等. 基于 ICEMD 及 AWOA 优化 ELM 的机械故障诊断方法[J]. 仪器仪表学报, 2019, 40(11): 172-180.
- ZANG SH Q, YUAN SH Y, YAO Y Y, et al. Machinery fault diagnosis method based on ICEMMD and AWOA optimized ELM [J]. Chinese Journal of Scientific Instrument, 2019, 40(11): 172-180.

- [22] 赵超, 陈肇泉, 王斌, 等. 基于互信息和 IGSA 优化 ELM 的重整芳烃收率软测量[J]. 仪器仪表学报, 2019, 40(3): 255-263.

ZHAO CH, CHEN ZH Q, WANG B, et al. Soft sensor modeling for reforming aromatic hydrocarbon yield based on MI and IGSA optimized ELM[J]. Chinese Journal of Scientific Instrument, 2019, 40(3): 255-263.

作者简介



唐圣学(通信作者), 2001 年于吉首大学获得学士学位, 2004 年于湖南大学获硕士学位, 2008 年于湖南大学获博士学位, 现为河北工业大学教授, 主要研究方向为电力电子技术、新能源发电技术。

E-mail: tsx@hebut.edu.cn

Tang Shengxue (Corresponding author) received his B. Sc. degree in 2001 from Jishou university, received his M. Sc. degree

in 2004 from Hunan university, received his Ph. D. degree in 2008 from Hunan university, now he is professor in Hebei University of Technology. His main research interests include power electronics technology and new energy power generation technology.



刁旭东, 2018 年于合肥工业大学获学士学位, 现为河北工业大学硕士, 主要研究方向为电力电子技术、光伏系统电弧故障检测技术。

E-mail: 215007695@qq.com

Diao Xudong received his B. Sc. degree in 2018 from Hefei University of Technology, now he is master student in Hebei University of Technology. His main research interests include power electronics technology and arc fault detection technology for photovoltaic system.