

DOI: 10.19783/j.cnki.pspc.231035

## 基于平稳小波变换的光伏直流串联电弧故障检测

王桐<sup>1</sup>, 史雯<sup>2</sup>, 石浩渊<sup>1</sup>, 康子良<sup>3</sup>

(1. 内蒙古电力集团有限责任公司内蒙古电力科学研究院, 内蒙古 呼和浩特 010020;

2. 内蒙古电力集团有限责任公司呼和浩特供电分公司, 内蒙古 呼和浩特 010020;

3. 燕山大学电气工程学院, 河北 秦皇岛 066004)

**摘要:** 光伏系统直流串联电弧故障具有随机性和隐蔽性的特点, 且容易受到外部环境和光伏系统内部噪声的影响, 难以检测。利用小波变换提取的电流时频域特征对电弧故障有很好的辨识度, 但面临小波基选取的问题。在采集大量电弧故障数据的基础上, 通过小波变换分析和对比实验, 提出一种针对常用电弧故障特征指标提取的最优小波基选取方法。通过此方法确定 bior4.4 小波基为提取电弧故障特征的最优小波基, 并由此构建基于 bior4.4 平稳小波变换的时频域特征。通过对比试验发现, 基于 bior4.4 的时频域特征对电弧故障的辨识度明显提高, 且表现出对正常噪声信号的抑制作用。为从多角度反映电弧故障特征, 补充时域特征, 并与时频域特征结合构成电流特征库, 利用随机森林算法实现电弧故障的诊断。电弧故障检测准确率达到 98.58%, 正常信号的误判率仅为 0.76%。

**关键词:** 电弧故障; 平稳小波变换; 最优小波基; 近似熵; 样本熵; 随机森林算法

### Photovoltaic DC series arc fault detection based on stationary wavelet transform

WANG Tong<sup>1</sup>, SHI Wen<sup>2</sup>, SHI Haoyuan<sup>1</sup>, KANG Ziliang<sup>3</sup>

(1. Inner Mongolia Power Research Institute, Inner Mongolia Power Group Co., Ltd., Hohhot 010020, China;

2. Hohhot Power Supply Branch, Inner Mongolia Power Group Co., Ltd., Hohhot 010020, China;

3. College of Electrical Engineering, Yanshan University, Qinhuangdao 066004, China)

**Abstract:** A PV DC series arc fault has the characteristics of randomness and concealment, and it is easily affected by the external environment and internal noise of the PV system, making it difficult to detect. The current time-frequency domain features extracted by wavelet transform can identify an arc fault very well, but it faces the problem of optimal wavelet base selection. Based on the collection of a large amount of arc fault data, this paper proposes an optimal wavelet base selection method for the extraction of commonly used arc fault characteristic indicators through wavelet transform analysis and comparative experiments. By this method, the bior4.4 wavelet base is determined to be the optimal wavelet base for extracting arc fault features, and the time-frequency domain features are constructed based on bior4.4 stationary wavelet transform. Through comparative experiments, it is found that the time-frequency domain feature based on bior4.4 can significantly improve the identification of an arc fault, and shows the suppression effect on normal noise signals. To reflect the characteristics of arc faults from multiple angles, it complements time-domain features, combines with time-frequency domain features to form a current feature library, and uses the random forest algorithm to realize the diagnosis of arc faults. The accuracy rate of arc fault detection reaches 98.58%, and the misjudgment rate of normal signal is only 0.76%.

This work is supported by the National Natural Science Foundation of China (No. 51877186).

**Key words:** arc fault; stationary wavelet transform; optimal wavelet basis; approximate entropy; sample entropy; random forest algorithm

## 0 引言

随着光伏发电产业规模不断扩大, 光伏系统直

流电弧故障的检测愈发受到人们的重视<sup>[1-2]</sup>。光伏系统直流母线的电压等级通常在几百至上千伏, 任何因线路老化、连接器松动等因素造成的回路微小间隙都可能导致直流电弧的产生, 甚至发生火灾事故。为此美国电气法规 NEC690.11 中规定: 直流电

基金项目: 国家自然科学基金项目资助(51877186)

压大于 80 V 的光伏系统, 必须配备检测故障直流电弧的检测装置和断路器。光伏系统直流电弧故障主要分为串联电弧故障、并联电弧故障和接地电弧故障, 接地电弧故障本质上属于并联电弧故障。并联电弧故障发生时, 电压电流会产生明显的跌落, 并伴随强烈的突变噪声, 而串联电弧故障发生时电压不会出现明显的跌落, 电流不会出现明显的畸变, 难以检测。因此对光伏直流串联电弧故障检测的研究是该领域的难点和热点<sup>[3]</sup>。

光伏系统直流串联电弧故障的实用性检测主要分为两大类<sup>[4-5]</sup>。一类是检测电弧产生时的物理特性, 如电磁辐射、弧光和弧声等, 此类检测方法对传感器的要求很高, 检测范围较小, 成本高, 且容易受到干扰, 一般只用于特定开关柜内。另一类是检测电弧产生时的电压电流变化, 电弧产生时电压电流会出现不同程度的畸变、谐波噪声增加等现象, 此类检测方法数据信号直接, 对传感器要求较低, 经济性强, 是目前的主流检测方法。

通过检测电压电流的波形变化来检测电弧故障的方法, 一般都考虑通过提取电信号的时域、频域或时频域特征进行检测<sup>[6]</sup>。相较于电压检测方法, 电流检测法具有更高的灵活性和适用性。电弧故障的时域特征检测法主要通过计算电流均值、方差、峭度等统计指标来检测直流电弧故障<sup>[7]</sup>。频域检测法则通过对故障电流进行傅里叶变换检测电弧特有的高频分量, 从而实现对接电弧故障的检测。时频检测法则通过小波变换或经验模态分解等方法提取电弧电流的特征值, 再通过阈值检测或机器学习等方法对接电弧故障进行判断。基于经验模态分解(empirical mode decomposition, EMD)或变模态分解(variational mode decomposition, VMD)提取电弧电流特征值的方法容易产生频谱混叠的现象, 导致电弧特征不突出, 并且 EMD 和 VMD 的检测时间更长, 对接电弧故障的响应速度慢, 而电弧故障的检测对快速性要求很高<sup>[8-10]</sup>。小波变换相较于 EMD 和 VMD 有更快的响应速度, 且具有检测精度高、抗干扰性好的优点, 但存在小波基选取的问题<sup>[5,7,11-12]</sup>。

目前关于小波基选取的研究尚未深入, 且大都集中在机械故障诊断领域。文献[13]通过对比小波基和信号的相似性来确定最优小波基, 将小波变换后的信噪比作为筛选最优小波基的依据。文献[14]采用噪声功率与噪声功率差作为最优小波基的判断标准。在电弧故障检测领域中, 多数文献对于小波基的选取都采用特定小波基筛选法或直接采取经验性的选取方法, 常用的小波基相对比较固定。文献[5]通过对比基于 bior1.5、db4 和 db10 小波变换后

的能量比指标来选择小波基。文献[3,8,15]分别选择 db4、db9 和 sym4 直接作为小波变换的基函数来提取电弧故障的特征。不同于一般直流系统, 就光伏系统直流电弧故障而言, 小波基的选取不仅影响电弧故障检测的准确率, 也会影响正常信号的误判率。光伏系统本身就易受到噪声信号和电流波动的干扰<sup>[16-17]</sup>, 其中最主要的干扰信号来源为光照强度变化造成的电流波动与最大功率跟踪(maximum power point tracking, MPPT)控制器带来的开关噪声。这些波动或噪声很容易被系统视为电弧故障, 造成不必要的跳闸<sup>[18-19]</sup>。目前文献中对于小波基的选取问题大都遵循了定性分析的方法, 有一定的主观性, 缺乏相应的客观选取标准。

本文针对小波基的选取提出了一种定量的标准化的选择方法。采用小波细节能量和小波细节能量熵两个指标构建了针对电弧故障检测的最优小波基选取标准。通过对比分析得出适用于直流电弧故障检测的小波基为 bior4.4。再引入近似熵和样本熵的概念, 构造出基于小波近似熵、小波样本熵时频域特征值。通过对比实验发现, 相较于以往研究中常用到的 db 小波族和 sym 小波族, 基于 bior4.4 小波基的时频域特征值不仅对接电弧故障有更高的分离度, 并且对接正常噪声信号有明显的抑制作用。在此基础上引入不受电流大小影响的统计指标方差、峰值、峰值系数和峭度因子, 构建电弧时域特征指标和时频域特征指标融合的电弧电流特征库。最后利用随机森林算法对接光伏直流电弧故障进行判断, 基于特征融合的电弧故障检测准确率达到 98.58%, 正常信号的误判率降低到 0.76%。

## 1 电弧数据采集及特性分析

### 1.1 实验平台的搭建

本文按照国标 GB14287.4—2014《电弧故障保护器的一般要求》和美国标准 UL1699—2011《电弧故障断路器安全标准》搭建了光伏直流串联电弧故障采集平台, 原理图如图 1 所示。

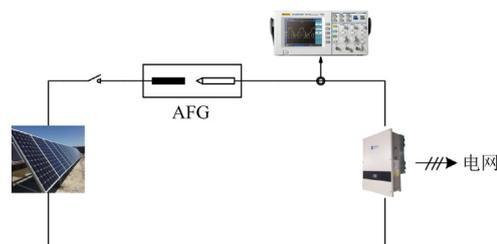


图 1 光伏直流串联电弧故障采集电路原理图  
Fig. 1 Schematic diagram of PV DC series arc fault acquisition circuit

如图 1 和图 2 所示,平台主要由光伏电池板、电弧故障发生器、并网逆变器和示波器组成。示波器采用 ZDS2024 设定采样率为 100 KSa/s。电流探头型号为 HCP8030D。电弧发生器由直径 6 mm 的固定碳棒电极和直径 6 mm 的尖端移动铜棒电极组成。

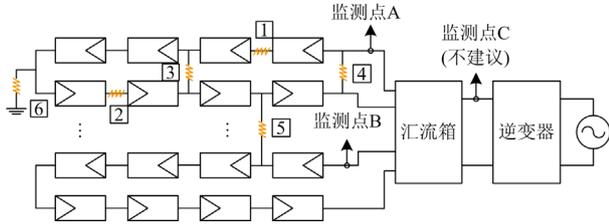


图 2 光伏直流串联电弧故障采集平台

Fig. 2 PV DC series arc fault acquisition platform

光伏组串为 16 串 2 并的连接方式,光伏直流母线接入并网逆变器输入端,逆变器输出端并网。光伏组件的主要参数如表 1 所示。

表 1 光伏组件参数

Table 1 PV module parameters

参数	光伏组件(多晶硅)	二个组串(32 个组件)
峰值功率/W	255	8160
峰值电压/V	30	480
峰值电流/A	8.49	16.98
开路电压/V	37.7	603.2
短路电流/A	9.014	18.028

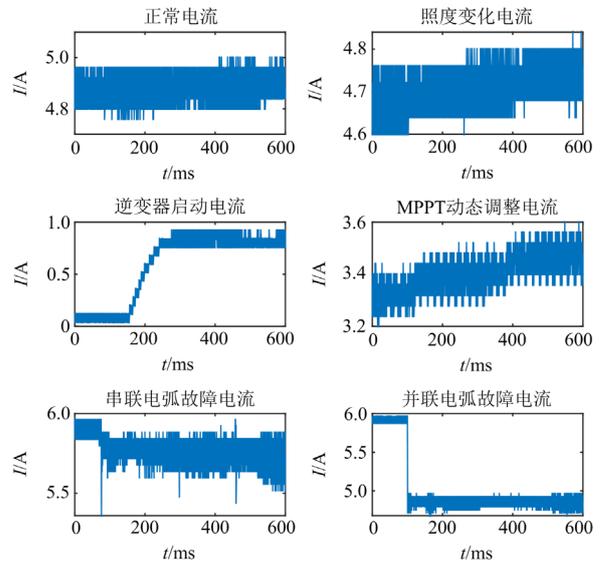
如图 2 所示,在光伏系统中,按电弧故障发生位置不同,可将电弧故障分为如下几类:其中位置 1、2 为串联电弧故障,位置 3、4、5 为并联电弧故障,位置 6 为接地电弧故障。为保证电弧故障检测的有效性,将监测点放置在支路光伏串的汇流箱输入端,也就是图 2 中监测点 A 和监测点 B 的位置。将监测点放置在 A、B 的位置能够有效监测其所在支路的电流,方便确定电弧故障所在支路,且在发生电弧故障时,方便系统快速切除故障支路,同时不会影响其他光伏支路的正常工作。不建议将监测点放置在 C 点是因为直流母线上汇聚了多支路电流,如果单独支路发生电弧故障,而其他支路正常运行时,经过汇流箱后,故障电流信号会被正常电流淹没,不利于电弧故障的准确检测,即使准确检测出电弧故障,也无法确定电弧故障所在的支路。

本文分别在 2022 年的 10—11 月,2023 年的 3—10 月采集到不同温度光照 MPPT 控制器动作条件下的光伏正常运行电流信号与光伏电弧故障电流信号样本 2000 份,每份样本包含 2048 个数据点。其中正常稳定电流信号 600 份,光照强度变化时电流信

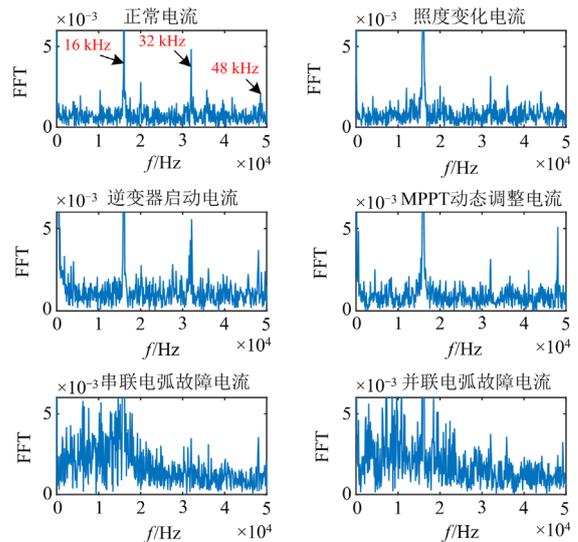
号 200 份,MPPT 动作时电流信号 200 份,电弧故障电流信号 1000 份。

### 1.2 光伏电流特性分析

光伏系统在运行过程中主要会受到光照、温度、负载、电网以及电力电子器件噪声等因素的影响。就位于直流侧的光伏系统直流电弧故障而言,对其影响最大的就是光照强度变化导致的电流波动以及逆变器的开关频率噪声。至于交流侧的电网波动或负载变化对直流侧的影响较小,且交流侧波动对直流侧的影响主要集中在低频部分,并不会对电弧故障检测常用的高频频段产生影响。图 3 给出光伏系统各类电流波形及其对应的电流频谱。



(a) 光伏系统电流类型



(b) 光伏系统电流频谱

图 3 光伏系统电流类型及频谱

Fig. 3 Photovoltaic system current type and spectrum

从图 3(a)中可以看出, 相比于正常电流或扰动电流, 电弧电流具有明显的噪声, 并伴随大量瞬时突变。从图 3(b)中可以看出, 光伏系统作为非恒定系统, 电流中本身就存在许多谐波噪声, 其中逆变器开关频率噪声及其倍频噪声较为突出, 这些噪声的存在会给电弧故障检测带来一定程度的干扰。当电弧产生时, 不论是串联电弧电流还是并联电弧电流都会出现大量的谐波注入, 且这些电弧谐波噪声大都集中在 50 kHz 以内的频段中<sup>[5-6,18-19]</sup>。单从对比串联电弧电流和并联电弧电流的频谱来看, 并不能将串联电弧与并联电弧电流进行明显的区分, 必须借助并联电弧产生时电压或电流的瞬时跌落等特性才能区分串联电弧故障和并联电弧故障, 但相比于并联电弧故障, 串联电弧产生时, 并不会出现明显的电流跌落, 电流不会出现大的畸变, 这就导致串联电弧故障比并联电弧故障更加难以检测, 并且对串联电弧故障检测有效的方法对并联电弧故障同样有效。因此本文的研究主要针对光伏系统直流串联电弧故障。

以图 2 中位置 1 处发生串联电弧故障为例, 光伏系统支路发生串联电弧故障时支路监测点 A 采集的电流数据和干路监测点 C 采集的电流数据以及对应的电流频谱, 如图 4 所示。监测点 A 电流中出现大量噪声突变, 频谱中也体现出明显的噪声谐波, 但监测点 C 电流中的噪声信号不太明显, 频谱中的谐波注入量也明显较弱, 这也进一步佐证了将监测点放置在支路的优势。

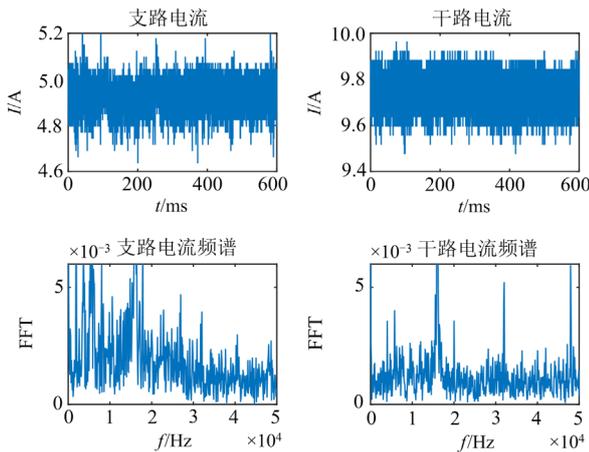


图 4 串联电弧下的支路电流和干路电流及其频谱

Fig. 4 Branch current and main current and their current spectrum under series arc fault

## 2 电弧故障特征值的提取

电弧故障特征值的提取本质上就是提取电弧故

障特有的信息, 并以此作为判断电弧故障的依据。无论是正常运行的电流数据还是电弧故障电流数据, 本质上都是一种时间序列。包含大量数据点的时间序列具有丰富的信息, 但信息内容并不直观, 需要通过相应的方法来提取其中的信息。

### 2.1 平稳小波变换

电弧故障特征提取主要分为时域特征提取、频域特征提取和时频域特征提取, 基于时频域特征电弧故障检测方法是目前研究的主流。电弧本质上是一种高频噪声并且电弧的检测对快速性要求很高, 因此用于检测电弧的特征量必须要同时具备一定的频率分辨率和时间分辨率。而时域特征不具有频率分辨率, 频域特征不具有时间分辨率, 因此时域特征与频域特征常被用作辅助变量来辅助时频域特征量, 进一步提高电弧故障检测的准确率。

小波变换和经验模态分解是常用的时频域特征提取方法。相较于经验模态分解, 小波变换能够分频段分析信号的局部特征, 且检测速度快、精度高、抗干扰性强。因此本文利用小波变换来提取电弧故障的时频域特征。

在实际的工程问题中, 常用的小波变换为离散小波变换。离散小波变换将原始信号通过高通滤波器和低通滤波器分解为小波细节系数和小波近似系数, 然后保留细节系数, 将近似系数进一步分解, 直达到达所需的分解层数。并且每一层的分解都采用了间隔采样, 信号每分解一次则长度减半<sup>[20]</sup>。

设  $f_k$  为离散采样数据, 令  $c_j = f_k$ 。离散小波变换的分解如式(1)所示。

$$\begin{cases} c_{j+1} = D_\epsilon H_L c_j \\ d_{j+1} = D_\epsilon G_L c_j \end{cases} \quad (1)$$

式中:  $c_{j+1}$  为  $c_j$  分解后的近似系数;  $d_{j+1}$  为  $c_j$  分解后的细节系数;  $j$  为分解层数;  $D_\epsilon$  为隔点采样算子;  $H_L$  为低通滤波器;  $G_L$  为高通滤波器。

相比于离散小波变换, 平稳小波变换是非抽样小波变换。平稳小波变换先将原始信号通过高通滤波器和低通滤波器进行分解, 得到小波细节系数和小波近似系数, 在进行下一层分解工作前对高通滤波器和低通滤波器进行差值补零形成新的高通滤波器  $G_L^j$  和低通滤波器  $H_L^j$ , 信号分解时无需进行间隔采样。平稳小波变换的分解如式(2)所示。

$$\begin{cases} c_{j+1} = H_L^j c_j \\ d_{j+1} = G_L^j c_j \end{cases} \quad (2)$$

相较于离散小波变换, 平稳小波变换没有下采样过程, 小波细节系数和近似系数与原始信号长度

相同,且小波系数是通过零相位滤波得到的,在时域上与原始时间序列严格对应,具有更高的时间分辨率<sup>[21]</sup>。并且平稳小波变换是非正交小波变换。平稳小波变换的小波基选择面更广,更加有利于选择适合电弧故障检测的小波基。因此本文选择平稳小波变换来提取电弧故障的时频域特征。

## 2.2 最优小波基的选取

利用小波变换来检测电弧故障虽然具有更快的检测速度,但其准确率和抗干扰性应与小波基的选取有关,选择合适的小波基能最大限度地提高检测精度和抗干扰性。

小波变换本质上是测量被分析的信号和具有平移因子和尺度因子的小波之间的相似性。由于不同的小波基有不同的特性,运用不同的小波基对同一信号进行分析会得到不同的结果。因此针对信号分析中不同的信息需求,应当采用不同的小波基。理论上,小波函数的选择和构造要求其具有一定的紧支集、正则性、对称性和消失矩等特性。紧支集保证小波有良好的时域分辨率;正则性影响频率分辨率的高低;对称性确保小波的滤波特性有线性相移,避免信号的失真;消失矩阶数反映能量的集中程度。但是紧支集和正则性是矛盾的,不能同时兼得,对称性和正交性也不能兼得;消失矩的大小决定了小波函数逼近光滑的能力,一般会优先考虑较高消失矩的小波函数,但随着消失矩的增加,支撑长度会变宽,运算量增加,所以消失矩阶数一般控制在4~9阶。综合考虑上述因素来选取小波基是目前常用的方法<sup>[22]</sup>。此方法有一定的借鉴意义,但终究是主观的和定性的。因此需要确定相应的客观标准作为最优小波基选择的依据。

信号通过小波变换后,被分解到不同尺度上。如果信号中包含某种需要检测的频率成分,则当此频率成分出现在对应尺度的小波变换中时该尺度的小波系数会有较高的幅值。此时计算该尺度下小波细节系数的能量就能有效地提取出需检测的频率,并且小波细节系数的能量越高,被检测信号与小波基越相似,基于小波变换的信号处理越有效。因此小波细节系数的能量可作为选择小波基的指标之一。

设 $X(N)$ 是包含 $N$ 个数据点的离散信号,其能量的定义如式(3)所示。

$$E(X) = \sum_{i=1}^N |X(i)|^2 \quad (3)$$

式中: $N$ 为信号数据的长度; $X(i)$ 为信号幅值。

通过小波变换后,信号 $X(N)$ 的能量可表示为式(4)。

$$E(W) = \sum_s \sum_i |W(s,i)|^2 \quad (4)$$

式中: $W(s,i)$ 为小波系数; $s$ 为小波尺度参数。

特定尺度下小波系数的能量可表示为式(5)。

$$E_s(W) = \sum_{i=1}^N |W(s,i)|^2 \quad (5)$$

小波系数能量能反映出单一尺度下小波变换对信号的有效处理程度,却无法反映出多尺度下信号的集中程度。就电弧电流信号而言,其中不仅包含了直流分量和电弧故障分量,还包含诸如逆变器开关噪声和环境噪声等。利用小波变换提取电弧故障的特征值,本意是利用小波放大电弧故障分量。而最优小波基的选取则是为了在突出或放大电弧故障分量的同时,抑制不需要的开关噪声或环境噪声等分量。因此有效的电弧故障分量提取需要各尺度小波系数能量相对集中。在此引入信息熵的概念,信息熵是一种常用的表现信号信息含量的量化指标。信息熵越大,说明信号中成分越多,随机性越强,信息熵越小,说明信号成分越单一,信息集中度越高。信息熵的定义如式(6)所示。

$$H = -\sum_{j=1}^n p_j \cdot \log_2 p_j \quad (6)$$

式中: $p_j$ 表示信号源中每种成分出现的概率; $n$ 表示信号中所含的成分数量。

将小波系数能量与信息熵相结合,建立小波能量熵,如式(7)所示。

$$H(W) = -\sum_{s=1}^{N_0} p_s \cdot \log_2 p_s \quad (7)$$

式中: $N_0$ 表示小波的分解层数; $p_s = \frac{E_s(W)}{E(W)}$ ,

$$\sum_{s=1}^{N_0} p_s = 1, \text{ 当 } p_s = 0 \text{ 时, } p_s \cdot \log_2 p_s = 0。$$

由上述分析可得出小波能量熵取值范围,如式(8)所示。

$$0 \leq H(W) \leq \log_2 N_0 \quad (8)$$

如果所有小波系数能量的分布概率都相同,即 $p_s = \frac{1}{N_0}$  ( $s=1,2,\dots,N_0$ ),则 $H(W) = \log_2 N_0$ ,而当只有一个小波系数能量不为零时,即 $p_s = 1$  ( $s$ 取 $1 \sim N_0$ 中的唯一值)时, $H(W) = 0$ 。

因为电弧故障具有高频特性,所以在对电弧故障信号进行小波分析时,只选用小波细节分量忽略小波近似分量。利用合适的小波基在对信号进行分解时,应当在少数尺度上产生较大的小波细节系数,

而在其余尺度上产生幅值较小或可忽略的小波细节系数。小波细节系数幅值越大表明提取的电弧故障信号特征越明显, 此时的小波细节能量也越大, 较大的小波细节系数只出现在单个或少数尺度上, 则表明此小波基对电弧故障信号更加敏感, 信息的提取更加集中, 此时小波细节能量熵也越小。

通过上述分析可以得出针对光伏系统直流串联电弧故障最优小波基选取的两个标准:

- 1) 小波细节能量最大化标准;
- 2) 小波细节能量熵最小化标准。

在此定义小波细节能量与小波细节能量熵的比值为能量熵比  $T(W)$ , 如式(9)所示。

$$T(W) = \frac{E(W)}{H(W)} \quad (9)$$

能量熵比可将上述两个最优小波基选取的标准统一为一个综合指标。最优小波基对应的能量熵比一定取最大值。

在以往的研究中, 常用的小波基多出自 db 小波族和 sym 小波族。综合考虑小波的紧支集和消失矩, 一般常选用 db4、db9 以及 sym4 作为小波变换的基函数。db 小波和 sym 小波具有正交性和近似对称性, 更适用于信号的压缩和重构, 近似对称性会导致信号的线性位移和相位失真。与具有正交性和近似对称性的小波相比, 双正交小波除了具备光滑性、紧支性等性质外, 还具备对称性, 能够保证小波在分解和重构过程中具有严格线性相位特性, 从而实现更好的奇异性检测<sup>[23]</sup>。因此也选用具有双正交性质的 bior 小波族和 rbio 小波族中的小波基进行对比实验。考虑到消失矩过大或过小都会对小波变换的结果产生不利影响, 所以选择的双正交小波基为 bior2.4、bior3.1、bior4.4、rbio2.4、rbio3.1 和 rbio4.4。

对上述小波基进行对比实验, 结果如表 2 所示。bior4.4 小波基有最大的小波细节能量和最小的的小波细节能量熵, 因此 bior4.4 小波基可作为提取直流电弧故障时频域特征值的最优小波基。

表 2 最优小波基选取

Table 2 Selection of optimal wavelet basis

小波基	小波细节能量	小波细节能量熵	能量熵比
bior3.1	57.32	1.11	51.64
bior2.4	79.12	1.32	59.94
bior4.4	208.47	0.55	379.04
rbio3.1	82.68	1.20	68.90
rbio2.4	52.63	1.09	48.28
rbio4.4	57.32	1.11	51.64
db4	57.29	1.13	50.70
db9	55.36	0.96	57.67
sym4	57.29	1.13	50.70

## 2.3 时频域特征值

电流信号通过平稳小波变换后被分解为小波近似系数和若干层小波细节系数。若单纯利用小波分解后的小波系数来区分电弧故障, 会面临数据繁杂、特征不突出的问题。因此, 本文引入近似熵、样本熵的概念, 构成小波近似熵和小波样本熵作为电弧检测的时频特征<sup>[24]</sup>。小波近似熵和小波样本熵可以定量描述各尺度小波细节系数序列的复杂程度, 熵值越大时间序列的复杂程度越高, 这对表征故障特征十分有利。

近似熵的基本原理:

设时间序列  $X(N) = \{x(1), x(2), x(3), \dots, x(N)\}$ , 对  $X(N)$  进行  $m$  维的相空间重构, 如式(10)所示。

$$X_m(i) = \{x(i), x(i+1), \dots, x(i+m-1)\} \quad (10)$$

式中,  $i = 1, 2, \dots, N - m + 1$ 。

定义  $X_m(i)$  与  $X_m(j)$  之间的间距为  $d[X_m(i), X_m(j)]$ , 如式(11)所示。

$$d[X_m(i), X_m(j)] = \max |x(i+k) - x(j+k)| \quad (11)$$

式中:  $j \neq i$ ;  $k = 0, \dots, m - 1$ 。

统计向量  $X_m(i)$  与  $X_m(j)$  之间的距离  $d[X_m(i), X_m(j)] \leq r$  的个数, 记为  $C_i$ 。其中  $r = k \cdot \text{std}(X(N))$ ,  $k > 0$  为给定相似容限。并计算  $C_i$  与所有矢量的比值  $C_i^m(r)$ , 如式(12)所示。

$$C_i^m(r) = \frac{C_i}{N - m + 1} \quad (12)$$

对  $C_i^m(r)$  进行取对数运算, 再求其对所有  $i$  的平均值  $C^m(r)$ , 如式(13)所示。

$$C^m(r) = \frac{1}{N - m + 1} \sum_{i=1}^{N-m+1} \ln C_i^m(r) \quad (13)$$

对  $X(N)$  进行  $m+1$  维的相空间重构, 重复上述步骤, 得到  $C^{m+1}(r)$ , 如式(14)所示。

$$C^{m+1}(r) = \frac{1}{N - m} \sum_{i=1}^{N-m} \ln C_i^{m+1}(r) \quad (14)$$

近似熵  $ApEn(m, r)$  的定义如式(15)所示。

$$ApEn(m, r) = \lim_{N \rightarrow \infty} [C^m(r) + C^{m+1}(r)] \quad (15)$$

对于有限长度的观察序列, 近似熵的估计值如式(16)所示。

$$ApEn(m, r) = C^m(r) + C^{m+1}(r) \quad (16)$$

样本熵是基于近似熵改进而来的, 不依赖数据长度且具有更高的计算精度。为了节约篇幅, 直接给出样本熵  $SampEn(m, r)$  的定义, 如式(17)所示。

$$SampEn(m, r) = \lim_{N \rightarrow \infty} \left\{ -\ln \left[ \frac{B^{m+1}(r)}{B^m(r)} \right] \right\} \quad (17)$$

式中,  $B^m(r)$  与近似熵中的  $C^m(r)$  一致。

对于有限长度的观察序列, 样本熵的估计值如式(18)所示。

$$SampEn(m, r) = -\ln \left[ \frac{B^{m+1}(r)}{B^m(r)} \right] \quad (18)$$

考虑到计算复杂度, 最终选定近似熵和样本熵的相似容限为 0.2, 重构维数为 2。

除上述近似熵和样本熵外, 还引入常用的统计学指标, 并在排除电流值影响的前提下, 选取方差、峰峰值、峰值系数和峭度因子与小波变换相结合构成检测电弧的时频域特征量, 如表 3 所示。

表 3 统计指标公式

Table 3 Statistical index formula

特征指标	表达式
方差	$\sigma^2 = \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{X})^2$
峰峰值	$X_{peak} = X_{max} - X_{min}$
峰值系数	$C = \frac{X_{RMS}}{X_{peak}}$
峭度因子	$K_f = \frac{\frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{X})^4}{X_{RMS}^4}$

原始信号经小波变换后被分解为若干尺度小波细节系数。不同特征指标对于不同层的小波细节系数具有不同的敏感性。若在某尺度小波细节系数中的故障信号和正常信号的时频特征比值最大, 则该尺度小波细节系数可作为此时频特征的敏感分量。

如表 4 所示, 各尺度小波细节系数自上而下频率越来越低。小波各层对应的频谱范围为: d1 层(25~50 kHz)、d2 层(12.5~25 kHz)、d3 层(6.25~12.5 kHz)、d4 层(3.125~6.25 kHz)。在 d1 层中的小波近似熵和小波样本熵对故障信号和正常信号的区分度最大。因此 d1 层小波细节系数可作为小波近似熵和小波样本熵的敏感层。

表 4 近似熵与样本熵的敏感层

Table 4 Sensitive layer of approximate entropy and sample entropy

各尺度 小波系数	小波近似熵			小波样本熵		
	故障	正常	比值	故障	正常	比值
d1	2.823	1.292	2.185	3.495	1.295	2.699
d2	1.247	0.981	1.271	1.329	0.962	1.382
d3	1.133	0.955	1.186	1.138	0.964	1.181
d4	0.966	0.997	0.969	0.958	1.006	0.952
d5	1.031	1.017	1.014	1.003	1.021	0.983
d6	0.975	0.934	1.044	0.897	0.924	0.971
d7	0.935	0.722	1.295	0.849	0.706	1.202

如表 5 所示, d4 层小波细节系数中的方差、峰峰值和峭度因子对故障信号和正常信号的区分度最大, d1 层小波细节系数中的峰值系数对故障信号和正常信号的区分度最大。综上所述, 各特征指标的敏感层数集中在前 4 层。为了尽可能地减少能量泄露, 降低计算量, 小波分解层数越少越好。综合上述分析, 选定平稳小波变换的分解层数为 4 层。

表 5 统计指标的敏感层

Table 5 Sensitive layer of statistical indicator

各尺度 小波系数	方差	峰峰值	峰值系数	峭度因子
	故障/正常	故障/正常	故障/正常	故障/正常
d1	2.467	2.016	0.787	0.183
d2	3.167	2.154	0.827	0.114
d3	4.157	2.497	0.804	0.094
d4	8.471	2.604	1.003	0.063
d5	4.757	2.299	0.925	0.093
d6	4.810	2.436	0.878	0.124
d7	3.098	1.907	0.932	0.137

图 5—图 7 给出基于 bior4.4 小波基的时频特征计算结果。选取 12 组不同电流下的电流数据进行时频域分析, 每组数据包含相同电流下的故障电流数据、正常电流数据、MPPT 动作电流数据和光照强

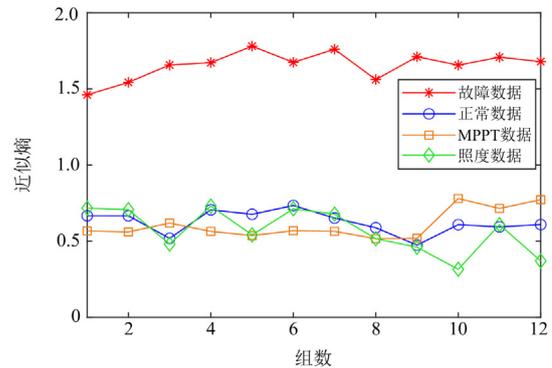


图 5 近似熵特征对比

Fig. 5 Comparison of approximate entropy eigenvalues

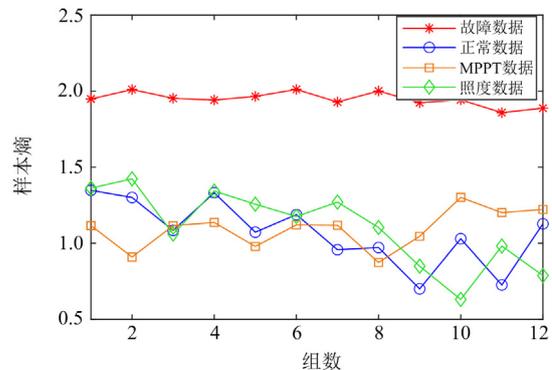


图 6 样本熵特征对比

Fig. 6 Comparison of sample entropy eigenvalues

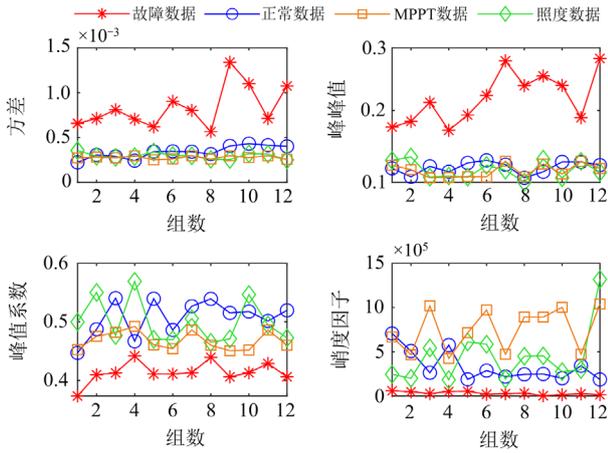


图 7 统计指标特征对比

Fig. 7 Comparison of statistical indicators eigenvalues

度变化时的电流数据。小波近似熵和小波样本熵展现出良好的电弧故障区分度，并且对电流波动和噪声有明显的抑制作用。小波方差、小波峰峰值和小波分值系数对故障信号也具有较明显的区分度，但相较于小波能量熵和样本熵，其故障特征值波动较大。小波峭度因子对电弧故障有一定的区分作用。统计指标的时频特征值波动大，从侧面反映出电弧故障噪声和突变的随机性。

### 3 基于不同小波基时频特征的对比实验

本节的主要内容是通过对比实验来验证最优小波基的选取结果。设：

- $R_1$  为故障电流的时频域特征值；
- $R_2$  为正常电流的时频域特征值；
- $R_3$  为照度变化电流的时频域特征值；
- $R_4$  为 MPPT 动作电流的时频域特征值。

在此定义故障特征与正常特征的分离比为  $R_1/R_2$ ，故障特征与照度变化特征的分离比为  $R_1/R_3$ ，故障特征与 MPPT 动作特征的分离比为  $R_1/R_4$ ，这 3 组分离比为故障信号与正常运行信号的比值，所以统称这 3 组分离比为故障分离比。继续定义照度变化特征与正常特征的比值为  $R_3/R_2$ ，MPPT 动作特征与正常特征的比值为  $R_4/R_2$ ，这两组分离比为正常电流扰动信号与正常电流信号的比值，所以统称这两组分离比为扰动分离比。

选取不同电流下的故障电流数据、正常电流数据、照度变化电流数据以及 MPPT 动作电流数据各 50 组，在基于不同小波基的平稳小波变换下，计算各类数据的小波近似熵、小波样本熵、小波方差、小波峰峰值、小波峰值系数和小波峭度因子，并求

均值，再计算分离比，结果如表 6—表 11 所示。

故障分离比越大，表示特征值对电弧故障和正常状态的区分越明显，电弧特征的提取越有效；扰动分离比越小表示正常的电流波动和噪声信号特征值与正常平稳状态电流的特征值区分度越小，特征值对正常的噪声与扰动有明显的抑制作用。从表 6—表 11 中可以得出，基于 bior4.4 的小波近似熵和小波样本熵都具有最大的故障分离比和最小的扰动

表 6 近似熵分离比

Table 6 Approximate entropy separation ratio

小波基	故障分离比			扰动分离比	
	$R_1/R_2$	$R_1/R_3$	$R_1/R_4$	$R_3/R_2$	$R_4/R_2$
bior4.4	2.852	2.807	2.729	1.016	1.045
bior2.4	1.829	1.703	1.571	1.074	1.164
bior3.1	2.054	1.925	1.793	1.067	1.146
rbio2.4	1.891	1.751	1.557	1.080	1.215
rbio3.1	1.913	1.964	2.118	0.794	0.903
rbio4.4	2.194	1.949	1.649	1.126	1.331
db4	1.982	1.872	1.700	1.059	1.166
db9	1.519	1.478	1.418	1.028	1.071
sym4	2.126	1.859	1.702	1.144	1.249

表 7 样本熵故障分离比

Table 7 Sample entropy separation ratio

小波基	故障分离比			扰动分离比	
	$R_1/R_2$	$R_1/R_3$	$R_1/R_4$	$R_3/R_2$	$R_4/R_2$
bior4.4	3.455	3.306	3.156	1.045	1.094
bior2.4	2.050	1.908	1.833	1.074	1.118
bior3.1	2.730	2.511	2.462	1.087	1.109
rbio2.4	2.281	2.105	1.894	1.084	1.204
rbio3.1	2.131	2.148	2.376	0.992	0.897
rbio4.4	2.628	2.306	1.934	1.140	1.359
db4	2.645	2.492	2.401	1.061	1.102
db9	1.820	1.764	1.778	1.032	1.023
sym4	2.798	2.406	2.315	1.163	1.209

表 8 方差分离比

Table 8 Variance separation ratio

小波基	故障分离比			扰动分离比	
	$R_1/R_2$	$R_1/R_3$	$R_1/R_4$	$R_3/R_2$	$R_4/R_2$
bior4.4	4.236	4.340	4.356	0.976	0.972
bior2.4	3.115	3.376	3.744	0.923	0.832
bior3.1	1.810	1.980	2.664	0.914	0.679
rbio2.4	3.749	4.117	4.116	0.911	0.911
rbio3.1	3.370	3.599	2.590	0.936	1.301
rbio4.4	3.643	3.555	3.229	1.025	1.128
db4	3.170	3.536	3.453	0.896	0.918
db9	3.607	4.052	4.087	0.890	0.883
sym4	3.670	4.036	4.453	0.909	0.824

表 9 峰峰值分离比

Table 9 Peak-to-peak separation ratio

小波基	故障分离比			扰动分离比	
	$R_1 / R_2$	$R_1 / R_3$	$R_1 / R_4$	$R_3 / R_2$	$R_4 / R_2$
bior4.4	2.694	2.763	2.757	0.975	0.977
bior2.4	2.584	2.755	2.744	0.938	0.942
bior3.1	2.068	2.261	2.490	0.915	0.831
rbio2.4	2.551	2.747	2.701	0.929	0.944
rbio3.1	2.481	2.651	2.308	0.936	1.075
rbio4.4	2.511	2.694	2.685	0.932	0.935
db4	2.344	2.428	2.478	0.965	0.946
db9	2.491	2.484	2.405	1.003	1.036
sym4	2.490	2.542	2.588	0.980	0.962

表 10 峰值系数分离比

Table 10 Peak coefficient separation ratio

小波基	故障分离比			扰动分离比	
	$R_1 / R_2$	$R_1 / R_3$	$R_1 / R_4$	$R_3 / R_2$	$R_4 / R_2$
bior4.4	1.213	1.196	1.179	1.014	1.029
bior2.4	1.183	1.173	1.134	1.009	1.043
bior3.1	1.208	1.183	1.219	1.021	0.991
rbio2.4	1.161	1.163	1.096	0.998	1.059
rbio3.1	1.187	1.172	1.135	1.013	1.046
rbio4.4	1.163	1.161	1.102	1.002	1.055
db4	1.161	1.143	1.165	1.016	0.997
db9	1.173	1.178	1.197	0.996	0.980
sym4	1.183	1.173	1.133	1.009	1.044

表 11 峭度因子分离比

Table 11 Kurtosis factor separation ratio

小波基	故障分离比			扰动分离比	
	$R_1 / R_2$	$R_1 / R_3$	$R_1 / R_4$	$R_3 / R_2$	$R_4 / R_2$
bior4.4	1.937	1.947	1.950	0.995	0.993
bior2.4	1.934	1.941	1.945	0.996	0.994
bior3.1	1.901	1.925	1.954	0.988	0.973
rbio2.4	1.919	1.936	1.927	0.991	0.996
rbio3.1	1.888	1.911	1.803	0.988	1.047
rbio4.4	1.923	1.938	1.914	0.992	1.005
db4	1.907	1.918	1.937	0.994	0.985
db9	1.917	1.932	1.943	0.992	0.987
sym4	1.914	1.931	1.944	0.991	0.985

分离比。这说明 bior4.4 小波基与电弧故障信号的相似性最大，对电弧故障信号最敏感。同时也说明，bior4.4 小波基对电流波动和开关噪声的影响不敏感。基于 bior4.4 的统计指标特征值也对电弧故障展现出不同的分离效果。但利用统计指标计算的特征值对突变数值很敏感，所以特征值的波动很大。

#### 4 基于随机森林算法的电弧故障检测

##### 4.1 电流特征库的构建

考虑从多方位提取电弧特征值，除了上述时频域特征外，再补充近似熵、样本熵、方差、峰峰值、峰值系数、峭度因子的时域特征构建 12 维特征向量，构成电流特征库如式(19)所示。

$$T = \begin{bmatrix} I_{Ap(1)} & I_{Samp(1)} & I_{var(1)} & I_{pp(1)} & I_f(1) & I_{kf(1)} & I_{dAp(1)} & I_{dSam(1)} & I_{dvar(1)} & I_{dpp(1)} & I_{df(1)} & I_{dkf(1)} \\ I_{Ap(2)} & I_{Samp(2)} & I_{var(2)} & I_{pp(2)} & I_f(2) & I_{kf(2)} & I_{dAp(2)} & I_{dSam(2)} & I_{dvar(2)} & I_{dpp(2)} & I_{df(2)} & I_{dkf(2)} \\ \vdots & \vdots \\ I_{Ap(n_0)} & I_{Samp(n_0)} & I_{var(n_0)} & I_{pp(n_0)} & I_f(n_0) & I_{kf(n_0)} & I_{dAp(n_0)} & I_{dSam(n_0)} & I_{dvar(n_0)} & I_{dpp(n_0)} & I_{df(n_0)} & I_{dkf(n_0)} \end{bmatrix} \quad (19)$$

式中： $I_{Ap}$ 、 $I_{Samp}$ 、 $I_{var}$ 、 $I_{pp}$ 、 $I_f$ 、 $I_{kf}$  分别为近似熵、样本熵、方差、峰峰值、峰值系数、峭度因子的时频域特征指标； $I_{dAp}$ 、 $I_{dSam}$ 、 $I_{dvar}$ 、 $I_{dpp}$ 、 $I_{df}$ 、 $I_{dkf}$  分别为近似熵、样本熵、方差、峰峰值、峰值系数、峭度因子的时域特征指标； $n_0$  为电流样本数，总计 2000 份。

##### 4.2 随机森林算法

电弧故障检测问题可视为标准的二分类问题，很适用决策树算法来进行故障判断。决策树具有复杂度低、训练时间短、可解释性强等优点，但有拟合缺陷。随机森林是一种以决策树为基分类器的集成学习算法，其原理是利用 Bagging 或 Boosting 抽样方法，生成多个训练集，并针对每个训练集建立一个决策树模型，对各决策树进行多数投票的方

式进行决策。因此随机森林算法可以很好地弥补决策树的缺陷，同时提高了准确率，并且对异常值和噪声数据有很好的容忍度<sup>[25]</sup>。

随机森林算法作为由多棵决策树构成的集成学习算法，其构建要遵从以下 3 个原则<sup>[26]</sup>。

1) 决策树构建时的特征子集数量  $L_{sub}$  与样本特征总数  $L_f$  要满足如下关系：

$$L_{sub} \geq \log_2 L_f$$

2) 单棵决策树的准确率要高于 50%。

3) 各决策树之间尽可能相互独立，决策过程应有差异。

随机森林的构建过程如图 8 所示。

利用随机森林算法对电弧故障进行诊断的具体方法如下：

1) 从电流特征库中的 2000 个样本中, 随机选取 1600 个样本, 组成训练集, 剩余的 400 个样本组成测试集;

2) 从训练集中, 通过有放回抽样的方式随机抽取  $N(N \leq 800)$  个样本, 重复  $K$  次, 生成  $K$  组样本数为  $N$  的训练子集;

3) 从 12 个特征属性中随机选取  $n(n \leq 12)$  个属性, 组成特征属性子集;

4) 针对  $K$  组训练子集, 利用已经选定的特征属性子集, 分别生成  $K$  棵决策树;

5) 用生成的  $K$  棵决策树对测试集进行决策, 将  $K$  个决策结果进行集中投票后确定最终的决策结果。

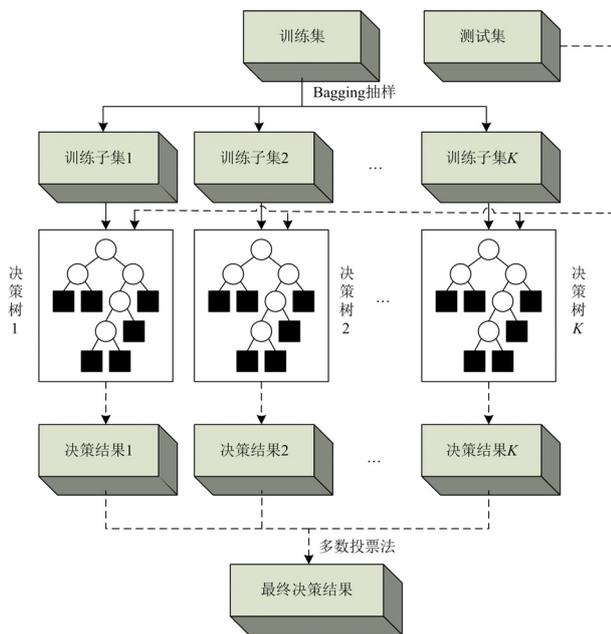


图 8 随机森林算法流程图

Fig. 8 Flow chart of random forest algorithm

电流特征库中有两类特征: 时域特征和时频域特征。实验中选取 3 组特征属性子集: 1) 时域特征属性子集; 2) 时频域特征属性子集; 3) 时域特征与时频域特征融合的属性子集。利用随机森林算法对各属性集进行电弧故障诊断, 结果如表 12 所示。

## 5 结论

本文在分析电弧特性以及小波变换原理的基础上, 提出了一种针对光伏系统直流电弧特征提取的最优小波基选取方法, 确定 bior4.4 小波基为光伏系统电弧故障检测的最优小波基。基于最优小波基构建检测电弧的时频域特征, 提高了对电弧故障的分辨率, 并对正常噪声信号有明显的抑制作用。为避免单一时频域特征的局限性, 从提取多方面电弧故

表 12 基于随机森林的电弧故障诊断

Table 12 Arc fault diagnosis based on random forest

属性集	小波基	正常信号判断		故障信号判断	
		准确率/%	误判率/%	准确率/%	误判率/%
时域特征	—	90.83	9.17	80.67	19.33
	bior4.4	96.75	3.25	95.43	4.57
	bior2.4	94.67	5.33	92.64	7.36
	bior3.1	94.23	5.77	93.72	6.28
	rbio2.4	93.78	6.22	91.89	8.11
	rbio3.1	95.63	4.37	94.32	5.68
	rbio4.4	94.86	5.14	93.86	6.14
	db4	94.12	5.88	92.79	7.21
	db9	95.42	4.58	94.25	5.75
	sym4	95.31	4.69	94.36	5.64
融合特征	bior4.4	99.24	0.76	98.58	1.42
	bior2.4	96.65	3.35	97.41	2.59
	bior3.1	97.46	2.54	96.85	3.15
	rbio2.4	95.35	4.65	94.53	5.47
	rbio3.1	96.84	3.16	95.76	4.24
	rbio4.4	95.69	4.31	94.97	5.03
	db4	96.57	3.43	96.39	3.61
	db9	96.84	3.16	96.01	3.99
	sym4	97.12	2.88	96.31	3.69

障特征的角度出发, 补充信号的时域特征, 构建时频域特征与时域特征融合的电弧特征库。再利用随机森林算法实现电弧故障的诊断, 通过对 2000 份数据进行实验, 电弧故障检测准确率达 98.58%, 正常信号的误判率仅为 0.76%。此方法在提高电弧故障检测准确率的同时, 对正常扰动信号的误判率也明显降低。在保证光伏系统稳定运行的前提下, 为光伏系统的电弧故障检测提供了一种新思路。

## 参考文献

- [1] 孟羽, 李兴文, 吴子豪, 等. 光伏系统直流故障电弧时频域特性及其复合模型研究[J]. 高压电器, 2022, 58(5): 23-30,40.  
MENG Yu, LI Xingwen, WU Zihao, et al. Research on time-frequency characteristics and composite models of DC arc faults in photovoltaic system[J]. High Voltage Apparatus, 2022, 58(5): 23-30, 40.
- [2] 张冠英, 赵若姿, 王尧. 基于 FCM 算法的光伏系统电弧故障检测方法研究[J]. 高压电器, 2022, 58(5): 15-22.  
ZHANG Guanying, ZHAO Ruozhi, WANG Yao. Study on arc fault detection method of photovoltaic system based on FCM[J]. High Voltage Apparatus, 2022, 58(5): 15-22.
- [3] 唐圣学, 刁旭东, 陈丽, 等. 光伏发电系统直流串联微弱故障电弧检测方法研究[J]. 仪器仪表学报, 2021,

- 42(3): 150-160.  
TANG Shengxue, DIAO Xudong, CHEN Li, et al. Study on detection method of weak series DC fault arc in PV power generation systems[J]. Journal of Instrument and Apparatus, 2021, 42(3): 150-160.
- [4] 熊庆, 陈维江, 汲胜昌, 等. 低压直流系统故障电弧特性、检测和定位方法研究进展综述[J]. 中国电机工程学报, 2020, 40(18): 6015-6027.  
XIONG Qing, CHEN Weijiang, JI Shengchang, et al. Review of research progress on characteristics, detection and localization approaches of fault arc in low voltage DC system[J]. Proceedings of the CSEE, 2020, 40(18): 6015-6027.
- [5] 牟龙华, 王伊健, 蒋伟, 等. 光伏系统直流电弧故障特征及检测方法研究[J]. 中国电机工程学报, 2016, 36(19): 5236-5244, 5405.  
MU Longhua, WANG Yijian, JIANG Wei, et al. Study on characteristics and detection method of DC arc fault for photovoltaic system[J]. Proceedings of the CSEE, 2016, 36(19): 5236-5244, 5405.
- [6] 李松浓, 晏尧, 向菲, 等. 光伏直流系统故障电弧检测方法研究综述[J]. 电测与仪表, 2024, 61(2): 10-16.  
LI Songnong, YAN Yao, XIANG Fei, et al. A comprehensive review on detection method for DC fault arc in photovoltaic system[J]. Electrical Measurement & Instrumentation, 2024, 61(2): 10-16.
- [7] 丁锐, 陈羽, 孙伶俐, 等. 基于邻波电流差与随机性的交流串联电弧故障识别[J]. 电力系统保护与控制, 2023, 51(8): 169-178.  
DING Rui, CHEN Yu, SUN Lingyan, et al. Series arc fault detection in low-voltage AC power lines based on absolute difference of the neighboring waveform of the current and randomness[J]. Power System Protection and Control, 2023, 51(8): 169-178.
- [8] 黄宵宵, 吴春华, 李智华, 等. 光伏系统直流电弧故障检测方法对比研究[J]. 太阳能学报, 2020, 41(8): 204-214.  
HUANG Xiaoxiao, WU Chunhua, LI Zhihua, et al. Comparison of DC arc fault detection methods for photovoltaic system[J]. Acta Energiac Solaris Sinica, 2020, 41(8): 204-214.
- [9] 杨帆, 宿磊, 杨志淳, 等. 基于改进 CEEMDAN 分解与时空特征的低压供电线路串联故障电弧检测[J]. 电力系统保护与控制, 2022, 50(12): 72-81.  
YANG Fan, SU Lei, YANG Zhichun, et al. Series fault arc detection in low voltage power supply line based on improved CEEMDAN decomposition and spatial-temporal features[J]. Power System Protection and Control, 2022, 50(12): 72-81.
- [10] 白浩, 潘姝慧, 邵向潮, 等. 基于小波去噪与随机森林的配电网高阻接地故障半监督识别方法[J]. 电力系统保护与控制, 2022, 50(20): 79-87.  
BAI Hao, PAN Shuhui, SHAO Xiangchao, et al. A high impedance grounding fault semi-supervised identification method based on wavelet denoising and random forest[J]. Power System Protection and Control, 2022, 50(20): 79-87.
- [11] 高海洋, 王玮, 尚同同, 等. 基于小波能谱熵的串联型故障电弧检测方法[J]. 电工电能新技术, 2022, 41(12): 63-71.  
GAO Haiyang, WANG Wei, SHANG Tongtong, et al. Series fault arc detection method based on wavelet energy spectrum entropy[J]. Advanced Technology of Electrical Engineering and Energy, 2022, 41(12): 63-71.
- [12] 王建国, 王道瑞, 王少锋. 管道泄漏声发射信号降噪中最优小波基的选取[J]. 中国科技论文, 2018, 13(23): 2667-2671.  
WANG Jianguo, WANG Daorui, WANG Shaofeng. Selection of optimal wavelet base in noise reduction of acoustic emission signals in pipeline leakage[J]. China Sciencepaper, 2018, 13(23): 2667-2671.
- [13] 张奥, 姜宏, 章翔峰. 小波基最优化在齿轮箱振动信号中的应用分析[J]. 机械设计与制造, 2020(8): 147-150.  
ZHANG Ao, JIANG Hong, ZHANG Xiangfeng. The analysis of wavelet based optimization in the application gearbox vibration signal[J]. Mechanical Design & Manufacture, 2020(8): 147-150.
- [14] 许志鹏, 刘振坚, 庄德玉. 基于最优小波基的采煤机摇臂振动信号特征频率提取技术[J]. 煤炭技术, 2023, 42(1): 230-233.  
XU Zhipeng, LIU Zhenjian, ZHUANG Deyu. Frequency feature extraction application of shearer rocker arm vibration signal based on optimum wavelet base algorithm[J]. Coal Technology, 2023, 42(1): 230-233.
- [15] 马健凯. 光伏发电系统的电弧故障检测技术研究[D]. 济南: 山东建筑大学, 2020.
- [16] 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, 6183.  
WU Chunhua, HUANG Xiaoxiao, LI Zhihua, et al. Research on DC weak arc signal detection in photovoltaic system[J]. Proceedings of the CSEE, 2019, 39(20): 6025-6033, 6183.
- [17] 赵铁军, 孟菁, 宋岳奇, 等. 组串式光伏系统直流串联电弧故障检测与保护策略[J]. 电力系统保护与控制, 2020, 48(20): 74-82.  
ZHAO Tiejun, MENG Jing, SONG Yueqi, et al. Series arc detection and protection on the DC side of string-type

- PVs[J]. Power System Protection and Control, 2020, 48(20): 74-82.
- [18] 吴春华, 徐文新, 李智华, 等. 光伏系统直流侧故障电弧危害分析及保护策略[J]. 太阳能学报, 2020, 41(9): 198-206.  
WU Chunhua, XU Wenxin, LI Zhihua, et al. DC arc-fault hazards analysis and protection in photovoltaic system[J]. Acta Energetica Solaris Sinica, 2020, 41(9): 198-206.
- [19] 张冠英, 赵若姿, 王尧. 基于 FCM 算法的光伏系统电弧故障检测方法研究[J]. 高压电器, 2022, 58(5): 15-22.  
ZHANG Guanying, ZHAO Ruozhi, WANG Yao. Study on arc fault detection method of photovoltaic system based on FCM[J]. High Voltage Apparatus, 2022, 58(5): 15-22.
- [20] YIN Z, WANG L, ZHANG B, et al. An integrated DC series arc fault detection method for different operating conditions[J]. IEEE Transactions on Industrial Electronics, 2021, 68(12): 12720-12729.
- [21] 冯志鹏, 李学军, 褚福磊. 基于平稳小波包分解的水轮机非平稳振动信号希尔伯特谱分析[J]. 中国电机工程学报, 2006, 26(12): 79-84.  
FENG Zhipeng, LI Xuejun, CHU Fulei. Application of stationary wavelet packets decomposition based Hilbert spectrum to nonstationary hydraulic turbine vibration signal analysis[J]. Proceedings of the CSEE, 2006, 26(12): 79-84.
- [22] 费铭薇, 乐全明, 张沛超, 等. 电力系统故障录波数据压缩与重构小波基选择[J]. 电力系统自动化, 2005, 29(17): 64-67, 97.  
FEI Mingwei, YUE Quanming, ZHANG Peichao, et al. Wavelet selection of compression and reconstruction algorithm based on digital recorded data from a faulted power system[J]. Automation of Electric Power Systems, 2005, 29(17): 64-67, 97.
- [23] CHEN S, LI X, 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.
- [24] 周付明, 刘武强, 杨小强, 等. 基于精细化改进多尺度快速样本熵的旋转机械故障诊断方法研究[J]. 机械强度, 2023, 45(1): 1-8.  
ZHOU Fuming, LIU Wuqiang, YANG Xiaoqiang, et al. Research on fault diagnosis method of rotating machinery based on refined improved multiscale fast sample entropy[J]. Journal of Mechanical Strength, 2023, 45(1): 1-8.
- [25] 杨贺雅, 邢纹硕, 陈聪, 等. 基于随机森林二分类器的模块化多电平换流器子模块开路故障检测方法[J]. 中国电机工程学报, 2023, 43(10): 3916-3928.  
YANG Heya, XING Wenshuo, CHEN Cong, et al. A fault detection and location strategy for sub-module open-circuit fault in modular multilevel converters based on random forest binary classifier[J]. Proceedings of the CSEE, 2023, 43(10): 3916-3928.
- [26] 杨杰, 吴浩, 董星星, 等. 基于电流故障分量特征和随机森林的输电线路故障类型识别[J]. 电力系统保护与控制, 2021, 49(13): 53-63.  
YANG Jie, WU Hao, DONG Xingxing, et al. Transmission line fault type identification based on the characteristics of current fault components and random forest[J]. Power System Protection and Control, 2021, 49(13): 53-63.

收稿日期: 2023-08-12; 修回日期: 2023-12-14

作者简介:

王桐(1987—), 男, 硕士, 工程师, 研究方向为新能源发电与电能计量; E-mail: hhwangtong@sina.com

史雯(1987—), 女, 高级工程师, 研究方向为油气实验分析; E-mail: 648915320@qq.com

康子良(1996—), 男, 通信作者, 硕士研究生, 研究方向为光伏系统故障电弧检测。E-mail: kzlwyx326@163.com

(编辑 魏小丽)