

DOI: 10.19783/j.cnki.pspc.241750

## 基于干路电信号的 RF-LightGBM 串联电弧故障诊断

薛阳<sup>1,2</sup>, 陈少雄<sup>2</sup>, 宋如楠<sup>2</sup>, 张蓬鹤<sup>2</sup>, 陈敢超<sup>2</sup>, 都正周<sup>3</sup>, 赵洪山<sup>1</sup>

(1. 华北电力大学电气与电子工程学院, 北京 102206; 2. 中国电力科学研究院, 北京 100192;  
3. 河南许继仪表有限公司, 河南 许昌 461000)

**摘要:** 针对低压配电系统中串联电弧故障在主干线路上诊断困难的问题, 提出一种基于随机森林(random forest, RF)和轻量梯度提升机(light gradient boosting machine, LightGBM)的诊断方法, 通过分析干路上采样电阻电压信号实现故障有效识别。首先, 依托多支路、多负载类型的串联电弧故障实验平台, 采集并分析了采样电阻电压信号特性, 发现多种工况下电弧故障特征表现为脉冲尖峰形式。然后, 对采样电阻信号进行低频衰减处理来放大电弧的高频脉冲特性, 以异常脉冲数突变量作为故障电弧的启动判据, 并进一步提取峰峰值、功率谱熵等时频域特征。最后, 利用 RF 筛选关键特征, 并通过 LightGBM 算法进行故障电弧诊断。结果表明, 所提方法在未知多负载工况下的诊断准确率可达 96.67%以上, 验证了该方法在复杂电路条件下具有良好的泛化能力和识别精度。

**关键词:** 低压配电系统; 串联电弧故障诊断; 采样电阻电压信号; 信号规则性; 轻量梯度提升机

### Series arc fault diagnosis based on transmission line electrical signals using RF-LightGBM

XUE Yang<sup>1,2</sup>, CHEN Shaoxiong<sup>2</sup>, SONG Runan<sup>2</sup>, ZHANG Penghe<sup>2</sup>, CHEN Ganchao<sup>2</sup>, DU Zhengzhou<sup>3</sup>, ZHAO Hongshan<sup>1</sup>  
(1. School of Electrical and Electronic Engineering, North China Electric Power University, Beijing 102206, China; 2. China Electric Power Research Institute, Beijing 100192, China; 3. XJ Metering Co., Ltd., Xuchang 461000, China)

**Abstract:** To address the difficulty of diagnosing series arc faults on the main lines of low-voltage distribution systems, a diagnostic method based on random forest (RF) and light gradient boosting machine (LightGBM) is proposed. The method achieves effective fault identification by analyzing voltage signals from sampling resistors on the main line. First, utilizing a series arc fault experimental platform with multiple branches and diverse load types, the characteristics of sampling resistor voltage signals are collected and analyzed. It is found that under various operating conditions, arc fault features typically appear as pulse spikes. Subsequently, the sampling resistor signals undergo low-frequency attenuation processing to enhance the high-frequency pulse characteristics of the arc. The sudden change in abnormal pulse count serves as the arc initiation criterion, and additional time-frequency domain features such as peak-to-peak value and power spectral entropy are extracted. Finally, RF is employed to select key features, and the LightGBM algorithm is used for arc fault diagnosis. Simulation results demonstrate that the proposed method achieves a diagnostic accuracy of over 96.67% under unknown multi-load operating conditions, validating its robust generalization capability and high recognition precision in complex circuit environments.

This work is supported by the Science and Technology Project of State Grid Corporation of China (No. 5700-202455276A-1-1-ZN).

**Key words:** low-voltage distribution system; series arc fault diagnosis; sampling resistor voltage signal; signal regularity; lightweight gradient boosting machine

## 0 引言

近年来,我国电气火灾事故多发且呈上升趋势,

而电气火灾的重要诱因之一是故障电弧。故障电弧的发生可以释放大量热量,其温度可高达数千摄氏度,导致电气火灾<sup>[1-4]</sup>。在配电系统中,电弧故障可分为串联型和并联型。与并联电弧故障不同,串联电弧故障由于电弧的阻抗效应,会使线路电流降低或增大不明显,从而使传统断路器难以检测到故障,

基金项目: 国家电网有限公司科技项目资助(5700-202455276A-1-1-ZN)

导致断路器无法及时跳闸<sup>[5]</sup>。因此，如何提取共性电弧特征并构建轻量化诊断模型，以实现复杂用电环境下低压交流串联故障电弧的可靠检测，已成为当前亟待解决的关键问题。

目前，串联故障电弧诊断方法主要分为 2 类：1) 通过电弧的电磁辐射、弧光、弧声等物理特性诊断电弧<sup>[6-8]</sup>，但这类方法适用于特定位置的电弧诊断，例如开关柜、变电站等场景；2) 通过分析电弧发生时的电压、电流波形，提取有效的时域、频域特征，并通过设定特征阈值或构建人工智能模型实现故障电弧诊断。相较于电压信号，电流更不易受到环境和位置的影响，因此目前大多数研究都集中于电流分析。在时频域阈值法中，时域方法主要利用切比雪夫距离、高阶中心矩、邻波电流差、波形因子、峰值因子等特征来诊断故障电弧<sup>[9-10]</sup>。在频域分析中常采用希尔伯特变换(Hilbert-Huang Transform, HHT)、小波变换(wavelet transform, WT)、快速傅立叶变换(fast Fourier transform, FFT)等方法来提取故障特征<sup>[11-12]</sup>。但阈值设置一般需要手动调整和依据专家经验，容易被线路工况干扰，因此时频域阈值法有一定的局限性。

近年来，人工智能方法在故障诊断中应用愈发广泛。人工智能方法通过提取故障电弧时频域特征，结合卷积神经网络(convolutional neural network, CNN)、概率神经网络(probabilistic neural network, PNN)等神经网络<sup>[13-18]</sup>及支持向量机(support vector machine, SVM)、K 最近邻(K-Nearest neighbors, KNN)、随机森林(random forest, RF)、极限梯度提升机(extreme gradient boosting, XGBoost)等机器学习算法<sup>[19-20]</sup>来诊断故障电弧。不同于阈值方法，神经网络与机器学习算法具备强大的自适应能力，能在训练后自动形成复杂的分类边界，这有助于提高诊断准确度。但随着新型电力系统的发展和非线性负载的不断增加，线路电流特征愈发复杂。此外，在干路检测中，还存在信号衰减、线路高频干扰、小电流电弧故障信息易淹没在干路信号中等问题。学者们通过互补集合经验模态分解(complementary ensemble empirical mode decomposition, CEEMD)、变分模态分解算法(variational mode decomposition, VMD)、经验模态分解(empirical mode decomposition, EMD)等算法<sup>[21-23]</sup>来提取故障电弧的共性时频域特征或重构信号使故障信息更为明显，或采用高频耦合电路<sup>[24]</sup>、差分耦合法<sup>[25-26]</sup>等硬件方法有效提取电弧电流高频信息。文献<sup>[27]</sup>发现通过采样电阻提取的原始电流信号包含更丰富的电弧高频信息。采样电阻无带宽限制，对于线路中电流的原始特性可以

较好地保存，且信号时域波形的故障特征会统一呈现为脉冲尖峰形态。但小功率负载产生的电弧信息不仅易淹没在干路电流中，还会受到其他负载运行产生的杂波、负载启停等干扰影响。所以需要主干线路电流信号中的电弧故障信息进行增强，实现任意支路故障电弧的快速准确诊断。

为解决以上问题，本文提出了一种基于干路电信号的随机森林-轻量级梯度提升机(random forest-light gradient boosting machine, RF-LightGBM)电弧故障诊断方法。首先，搭建了多负载、多支路的串联故障电弧采集平台，通过采样电阻采集串联故障电弧的电流信号，并进一步分析其信号在单负载电路和多负载电路中的规律性及电弧故障特征。其次，针对小功率负载的电弧信息易淹没的问题，设计了一个低频信号衰减电路对信号进行处理，分析处理后信号的时频域特征，采用 RF 筛选特征，最后通过贝叶斯优化的 LightGBM 模型实现故障电弧的有效诊断，并进行了消融实验验证。

## 1 实验方案及电弧特性分析

### 1.1 实验方案

为获取多工况下的采样电阻电压信号，即原始干路电流信号数据，研究单、多负载工况下电弧故障发生时的采样电阻电压信号波形特性，本文参照我国的电弧故障保护器标准 GB14287.4—2014 和美国的电弧故障断路器安全标准 UL1699—2011，并考虑我国复杂用电环境，搭建了串联故障电弧采集平台实现干路电信号采集，如图 1 所示。本实验采用由碳棒和铜棒电极组成的电弧发生器，其中铜棒为活动电极，碳棒为固定电极。通过缓慢调节二者间的间隙，产生串联故障电弧。负载线路电流流过采样电阻，通过示波器采集采样电阻两端的电压信号。同时在平台构建过程中，考虑线路阻抗对电弧信号衰减影响，在负载和采样电阻之间加入 100 m 单芯铜导线。

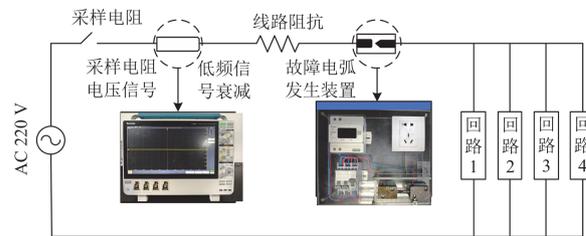


图 1 串联故障电弧采集平台

Fig. 1 Acquisition platform of series arc fault

实验采用 220 V、50 Hz 的交流电，并较多考虑易造成误报、漏报的非线性负载，选用负载如表 1 所示。

表 1 试验负载

Table 1 Loads of tests

负载类型	负载选择
阻性负载	饮水机(加热)550 W
非线性负载	荧光灯 40 W、空调(制冷)600 W、冰箱 150 W、 电磁炉 2100 W、微波炉 1150 W、 笔记本电脑 65 W、加湿器 24 W
感性负载	吸尘器 1500 W、洗衣机 160 W

分析指定负载: 1) 独立运行时发生电弧; 2) 系统满载下发生电弧。回路 1 包含电脑、加湿器、饮水机、吸尘器和空调, 回路 2 包含冰箱、电磁炉和微波炉, 回路 3 为洗衣机, 回路 4 为荧光灯。考虑单负载工况 20 种、多负载工况 18 种、单回路 4 种及双回路发生电弧的工况 12 种, 共 54 种工况, 如表 2 所示。同时为提高诊断模型的泛化能力及准确性, 每组样本包含 13 个周期的电流信号, 其中故障组中前 5 周期为正常状态, 后 8 周期为故障状态。每种工况下包括 30 组正常样本和 30 组故障电弧样本, 共 3240 组样本数据, 并设置采样频率为 250 kHz, 采样电阻为 3 m $\Omega$ 。

表 2 实验方案

Table 2 Experimental schemes

序号	工况	序号	工况
1-2	荧光灯	3-4	饮水机
5-6	吸尘器	7-8	洗衣机
9-10	空调	11-12	冰箱
13-14	电磁炉	15-16	微波炉
17-18	电脑	19-20	加湿器
21-22	电磁炉 + 冰箱	23-24	电磁炉 + 微波炉
25-26	微波炉 + 冰箱	27-28	电脑 + 吸尘器
29-30	电脑 + 饮水机	31-32	电脑 + 加湿器
33-34	吸尘器 + 饮水机	35-36	吸尘器 + 加湿器
37-38	饮水机 + 加湿器	39-40	回路 1
41-42	回路 2	43-44	回路 2+回路 4
45-46	回路 1+回路 4	47-48	回路 3+回路 4
49-50	回路 1+回路 2	51-52	回路 2+回路 3
53-54	回路 1+回路 3	—	—

## 1.2 故障电弧特性分析

### 1.2.1 单负载运行下发生电弧

通过多次实验提取各工况下的采样电阻电压正常信号与故障信号, 并剔除无效数据。单负载运行下的电弧信号波形如图 2 所示, 其中前 5 个周波为正常情况, 后 5 个周波为故障情况。

各种负载的采样电阻信号故障波形相比正常波形整体变化不大, 为三角波或正弦波的形态, 虽然杂波成分较多且经过传输线的衰减作用, 但电弧故障特征都较为明显, 呈现脉冲尖峰的形式且集中在

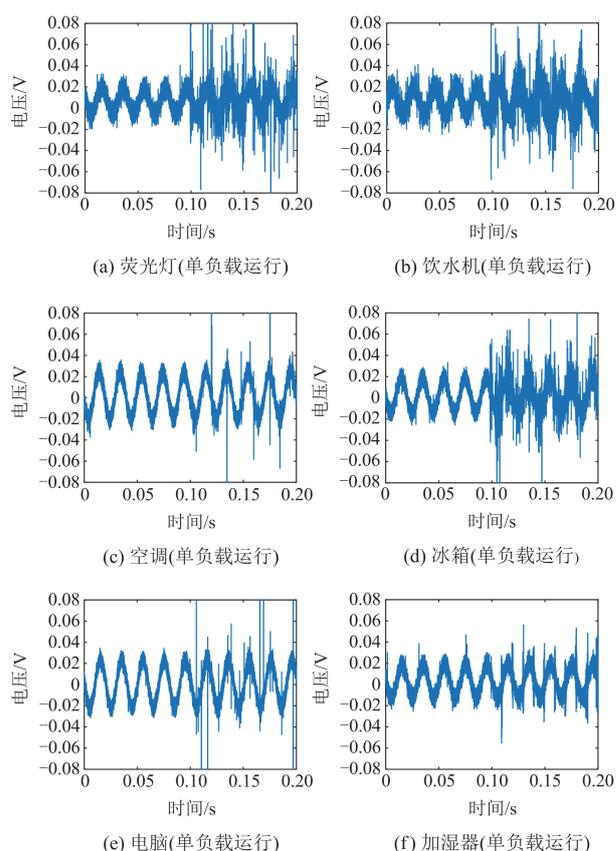


图 2 单负载运行下的电弧信号波形

Fig. 2 Arc signal waveform of single load operation

信号过零点和峰值时刻。这也与文献[27]中对空气压缩机、开关电源、电阻、荧光灯、电子灯光调节器、吸尘器、卤素灯负载工况下采样电阻信号的分析结果相符。电阻采样的电弧数据波形相对于电流互感器采样电流具有更多的谐波含量, 且信号波形为三角波或正弦波的形态, 故障特征呈现为脉冲尖峰的形式。

### 1.2.2 全负载运行下发生电弧

为探讨其他负载运行下单负载、多负载发生电弧时采样电阻信号是否呈现同样的规律及小功率负载产生的电弧信息在干路电流中的情况, 本文对其他负载都满功率运行(全负载运行)下单负载、多负载发生电弧的采样电阻信号进行了采样分析。单负载情况如图 3 所示。

全负载运行下各负载信号还是呈现三角波或正弦波的形态, 但随着负载运行数量的增多, 故障周波中的脉冲尖峰都有一定程度的减少, 且部分故障周波未呈现脉冲尖峰特征。其中空调和加湿器负载的电弧信息被掩盖的比较严重, 脉冲尖峰少且不突出, 难以直接通过采样电阻信号有效识别。同时其

他负载运行也会带来更多的杂波干扰。由图 3(a)、图 3(b)和图 3(e)可知,正常周波中有很明显的脉冲尖峰,且呈现杂乱无规律的特征。这导致异常脉冲的阈值准确设定面临挑战,需提取更具判别性的时频域多维特征,同时也需要对电弧故障信号进行增强。

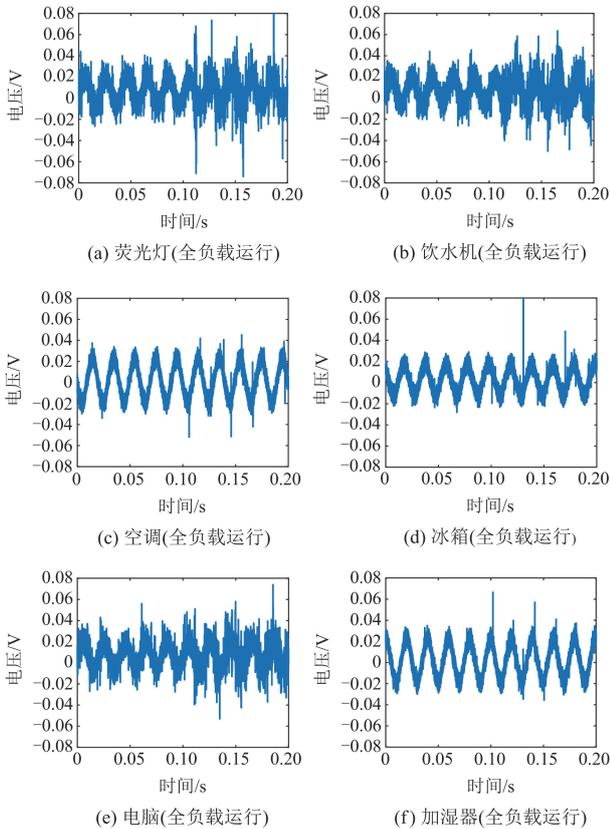


图 3 全负载运行下单负载的电弧信号波形

Fig. 3 Arc signal waveform for single load at full load operation

以图 3 中单周期内脉冲尖峰较少和功率较小的负载为例,全负载运行下多负载发生电弧的情况如图 4 所示。各工况下的信号时域波形及故障特征同样呈现相似的形态。不同于通过电流互感器直接提取的电流信号易受负载类型影响,通过采样电阻提取的单/多负载电路信号具有一定的规律性。这可以解决未知多负载电路中串联故障电弧电流特性变化或消失的关键问题,从而提取共性电弧特征,在干路

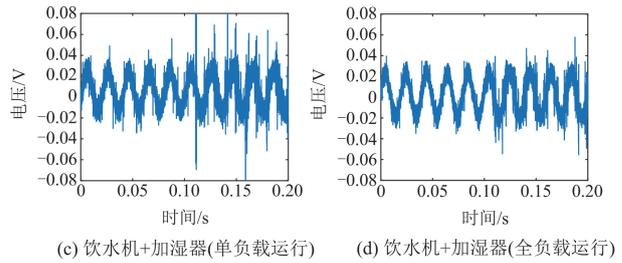
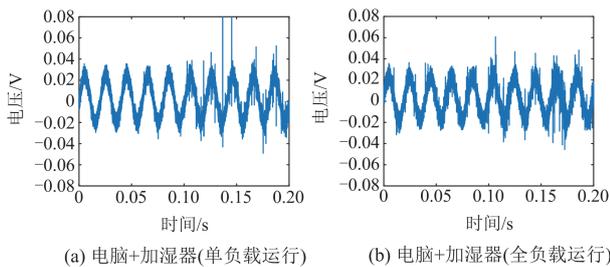


图 4 多负载的电弧信号波形

Fig. 4 Multi-load arc signal waveform

实现对复杂工况下的串联电弧精确诊断,提高诊断方法的泛化性能。

## 2 信号增强及电弧特征提取

### 2.1 信号增强

由于采样电阻获取的电流信号噪声水平高于电流互感器信号,直接采用 EMD、CEEMD 等模态分解方法易产生模态混叠现象,不利于故障信号增强。电弧区明显的频率范围易受负载类型影响,导致高通/带通滤波的截止频率难以准确设定。分析巴特沃斯、切比雪夫、椭圆滤波器的高通和带通滤波在多负载电弧信号中的效果,以区分明显的各频带为依据,设置相应的截止频率,结果表明故障增强效果有限且泛化能力较弱。根据现有文献[21-26]在多负载下的串联电弧检测效果,有效提取电弧电流高频信息有利于实现故障电弧的快速准确诊断。

基于单负载与多负载信号在波形/频谱上的相似性规律,本文对单负载的正常、故障信号频域进行观测,通过快速傅里叶变换方法,确定信号变化明显的特征区域。为便于对照分析,频域信号在取对数后进行归一化(50、100 Hz 分量单独归一化处理),结果如图 5 所示。图 5 中各负载正常、故障信号分别对应下行和上行。在 0~2 kHz 范围内各负载正常、故障信号相近,前 5 类负载的故障信号在 0~50 kHz 范围内普遍大于正常信号,冰箱、电磁炉、微波炉和电脑信号在 5~13 kHz 频带变化比较明显,而加湿器信号从频域上来观测较难区分。本文通过相对降低信号 0~5 kHz 频段的幅值,使原有明显的故障信息凸显出来,以解决小功率负载发生故障电弧时电弧信息易淹没在干路大电流中的问题。

参考文献[28]通过陷波滤波处理电弧电流信号,来放大其高频随机特性,本文设计了一个低频信号衰减电路,来减弱信号中基频和直流分量对计算结果的影响,放大被掩盖的电弧故障信息。通过设置合适的  $L_1$ 、 $R_1$ 、 $R_2$  值,使信号的各分量幅值随频率的降低而减小。电路具体计算过程为

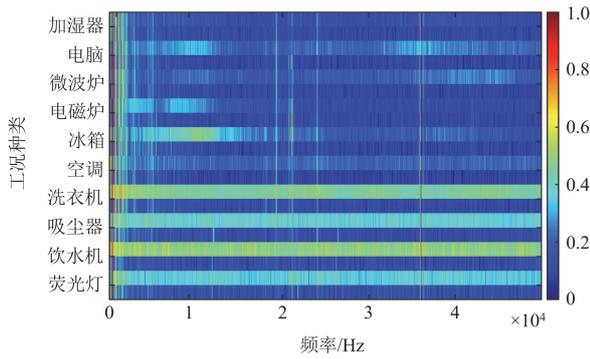


图5 单负载信号频谱分析

Fig. 5 Single-load signal spectrum analysis

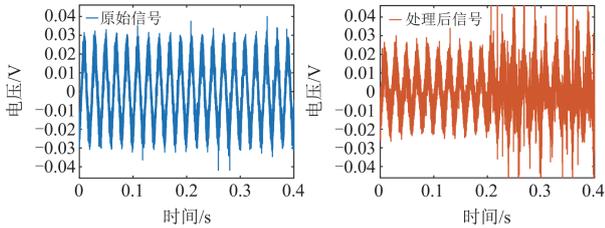
$$\left| \frac{\dot{U}_2(\omega)}{\dot{U}_1(\omega)} \right| = \left| \frac{R_1 + j\omega L_1}{R_2 + R_1 + j\omega L_1} \right| = \left| \frac{1}{1 + R_2 / (R_1 + j\omega L_1)} \right| \quad (1)$$

式中:  $R_2 = 1000 \text{ m}\Omega$ ,  $R_1 = 5 \text{ m}\Omega$ ,  $L_1 = 33 \text{ }\mu\text{H}$ ;  $\dot{U}_1$  为原采样电阻电压;  $\dot{U}_2$  为低频衰减处理后的电压;  $\omega$  为信号角频率。信号衰减呈现高通特性, 即频率越低, 幅值衰减越大。当频率为  $2.8 \text{ kHz}$  时, 该频率分量的幅值衰减约为  $6 \text{ dB}$ 。

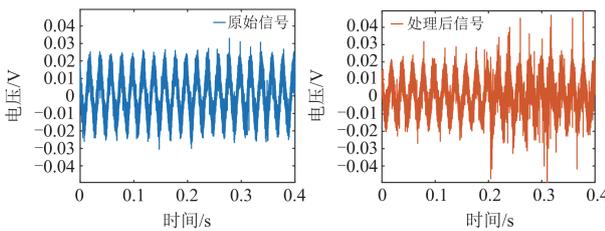
以全负载运行下空调、冰箱、加湿器发生电弧为例, 其信号在低频衰减处理前后的波形对比如图 6 所示。图 6 中信号后半段为故障区域。经过低频衰减处理后, 故障信号在单个周期内的异常脉冲尖峰数量显著增加, 且波形整体情况变化不大, 有利于提取共性的电弧特征。该低频信号衰减电路同样适用于多负载工况, 能较为有效地将采样电阻信号中电弧故障信息凸显出来, 更容易识别电弧故障。

## 2.2 时频域特征提取

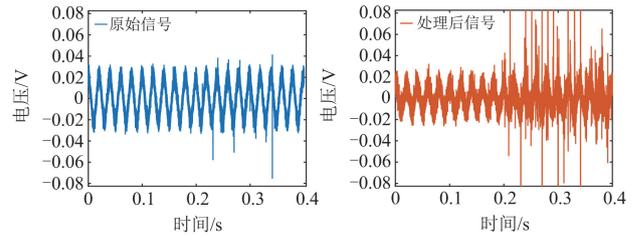
由采样电阻信号的故障电弧特性可知, 单/多负载工况下电弧信号时域波形均呈现脉冲尖峰特征。



(a) 空调(全负载运行)



(b) 冰箱(全负载运行)



(c) 加湿器(全负载运行)

图6 低频衰减处理前后的信号波形

Fig. 6 Signal waveform before and after low-frequency attenuation processing

由此表明, 异常脉冲数是一个有效区分正常和故障情况的电弧特征。设置采样电阻信号  $\{x[k]\}_{k=1}^N$  的脉冲计算公式为

$$\lambda[k] = \frac{|x[k] - \bar{x}[k]|}{\mu_{\text{abs}}} \quad (2)$$

$$\bar{x}[k] = \frac{1}{4} \left( \sum_{i \in S_k} x[i] - \max_{i \in S_k} x[i] - \min_{i \in S_k} x[i] \right) \quad (3)$$

式中:  $x[k]$  表示一个周期内第  $k$  个采样点的信号值;  $\bar{x}[k]$  表示信号第  $k$  个采样点周围值的均值;  $\mu_{\text{abs}}$  表示信号  $\{x[k]\}_{k=1}^N$  绝对值的均值;  $\lambda[k]$  为信号第  $k$  个采样点的脉冲比值; 集合  $S_k = [k-3, k] \cup (k, k+3]$ 。为提升电弧诊断的精度, 需考虑负载杂波与启停等因素带来的干扰。因此, 在对各工况的正常与故障组进行脉冲比值分析时, 需设定较高的脉冲比值阈值以准确识别异常脉冲。本文取  $\lambda[k] > 3$  为异常脉冲, 针对各工况下的每组数据, 统计其在连续 5 周期内的异常脉冲数  $N_{\text{arc}}$ , 总体情况如图 7 所示。为便于观察异常脉冲数变化不明显的工况, 图中将异常脉冲数的显示上限设置为 100。图中颜色亮度与  $N_{\text{arc}}$  大小呈正相关, 直观反映了异常脉冲数的多少。

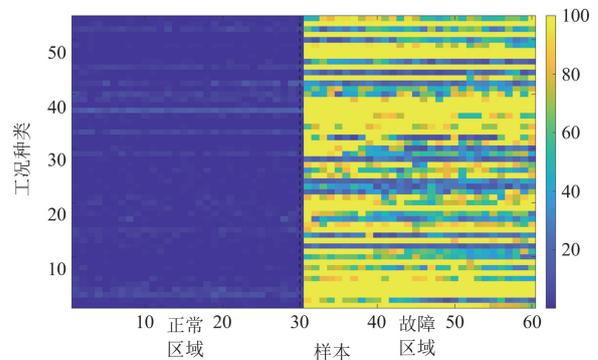


图7 各工况下异常脉冲数分布

Fig. 7 Distribution of abnormal pulse counts per condition

可以看出,大多数工况下的故障组中异常脉冲数都在 30 以上,相比正常组的异常脉冲数明显增多,可以很好地区分正常和电弧故障情况,说明  $N_{arc}$  是一个有效的、泛化性较强的电弧特征。故障组中工况 12、24、28、44(全负载运行下冰箱、电磁炉和微波炉、电脑和吸尘器、回路 2+回路 4)异常脉冲数相对较少,但其正常样本中仅存在少量异常脉冲,主要由负载启动及运行噪声所致。

考虑实际用电环境工况复杂性高且存在更多噪声与随机干扰,仅通过  $N_{arc}$  进行电弧故障诊断抗干扰能力不强,且只考虑了信号时域方面的特征。较多学者指出综合考虑故障信号的时频域特征,可以实现更为精确的故障诊断。因此本文进一步提取经过衰减处理后信号的时域和频域特征,参考文献 [19-22,28-29]先剔除定义接近的特征,提取 27 种特征。此外本文引入包络熵作为电弧诊断的新特征,它是一种衡量信号包络复杂度和不确定性的度量特征。计算包络熵的基本步骤如下。

1) 信号包络提取,对信号  $\{x[k]\}_{k=1}^N$  进行希尔伯特变换,得到解析信号  $z[k]$ ,并计算绝对值得到包络信号  $a[k]$  表示为

$$a[k] = |z[k]| = \sqrt{x[k]^2 + (\mathcal{H}\{x[k]\})^2} \quad (4)$$

式中:  $\mathcal{H}\{\}$  表示希尔伯特变换算子。

2) 归一化处理及熵值计算,将离散包络信号  $a[k]$  归一化为概率分布  $p[k]$ ,并利用香农熵公式计算包络信号的熵值,计算公式为

$$p[k] = a[k] / \sum_{i=1}^N a[i] \quad (5)$$

$$H = -\sum_{k=1}^N [p[k] \ln(p[k])] \quad (6)$$

式中:  $H$  表示包络熵值。本文共提取 29 种特征,如表 3 所示。由于其他特征量的计算方法已在文献 [19-22,28-29]描述,本文不再赘述其详细计算过程。

表 3 时频域特征

Table 3 Time and frequency domain features

序号	名称	序号	名称	序号	名称
1	异常脉冲数	11	峰值因子	21	谱峭度的峭度
2	皮尔逊相关系数	12	脉冲因子	22	频谱能量
3	峰峰值	13	裕度因子	23	频谱均值
4	整流平均值	14	重心频率	24	3、5 次谐波幅值之和
5	标准差	15	均方根频率	25	总谐波失真率
6	归零化峭度	16	频率方差	26	功率谱熵
7	偏度	17	频率标准差	27	能量熵
8	均方根	18	谱峭度均值	28	模糊熵
9	方根幅值	19	谱峭度标准差	29	包络熵
10	波形因子	20	谱峭度的偏度	—	—

### 2.3 特征筛选

为了提高模型的识别准确率,并减少冗余特征信息对模型的影响,本文使用 RF 进行特征筛选,提取有效的故障特征。首先,通过随机森林模型训练包含所有特征的数据集。然后,根据模型中每个特征的“重要性”评分即相应的特征权重来评估其对模型性能的贡献并排序,依次剔除影响最小的特征,然后重新对模型进行训练,以此来观察模型分类精度的变化。最终选择特征数量为 10,使模型的准确率和计算效率达到较好的平衡。特征数与准确率之间的关系及特征排序分别如图 8、图 9 所示。

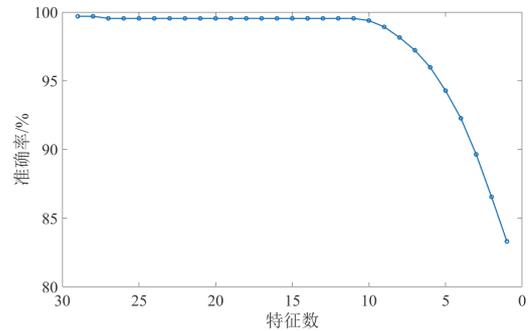


图 8 特征数与准确率之间的关系

Fig. 8 Relationship between feature data and accuracy

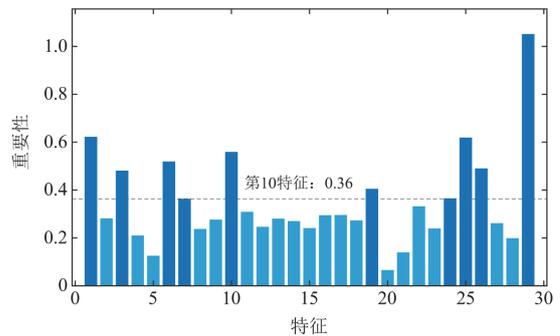


图 9 各特征重要性

Fig. 9 Importance of each feature data

取重要性前 10 的特征作为电弧诊断模型的输入向量,即异常脉冲数、峰峰值、归零化峭度、偏度、波形因子、谱峭度标准差、3 和 5 次谐波幅值之和、总谐波失真率、功率谱熵、包络熵。54 种工况下电弧故障特征区分效果如图 10 所示,为便于对比分析,将各工况的同类特征合并并且作归一化处理。每种工况 60 组样本,正常状态数据为前 30 组样本,故障状态数据为后 30 组样本,每种工况含 10 维故障特征,即  $60 \times 540$  维的故障特征矩阵。

由图 10 可以看出,除了偏度和谱峭度标准差对应的样本中部分区分效果不明显,其他特征的正常组和故障组有较为明显的区别。其中包络熵特征区

分效果最好, 表明通过 RF 筛选出来的特征能较好地地区分正常和故障类。

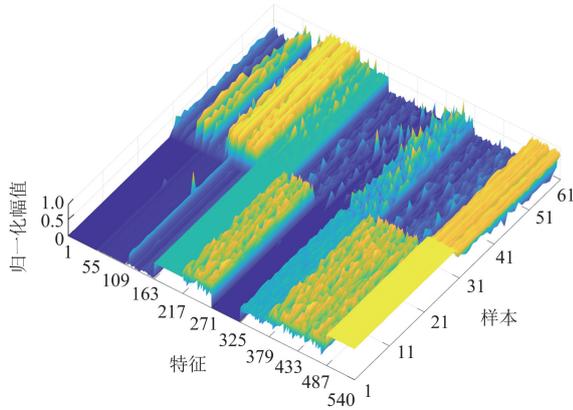


图 10 54 种工况下信号时频域特征

Fig. 10 Time-frequency domain features under 54 operating conditions

### 3 基于干路电信号的 RF-LightGBM 电弧故障诊断方法

#### 3.1 LightGBM 基本原理

LightGBM 是微软推出的一种分布式梯度提升算法构架, 旨在弥补 GBDT 在处理海量数据和高维特征时, 效率与可扩展性上的不足<sup>[30]</sup>。该算法通过加速直方图、限制深度的逐叶子生长、互补特征捆绑(exclusive feature bundling, EFB)及基于梯度的单边采样(gradient-based one-side sampling, GOSS)来优化梯度提升决策树(gradient boosting decision tree, GBDT), 具有训练快、精度高、内存消耗低, 适用分析大规模数据等优点, 能够满足低压交流串联故障电弧的诊断需求。在训练过程中, LightGBM 通过以下步骤构建决策树: 1) 初始化模型: 设定初始预测值; 2) 计算样本的一、二阶偏导数; 3) 构建决策树: 使用导数信息, 找到最佳的特征分裂点, 构建一棵新的决策树, 包括: 直方图构建、寻找最佳分裂点、生成左右子节点; 4) 更新模型预测值; 5) 重复步骤 2) 步骤 4), 迭代构建多棵树, 逐步提升模型的准确性。

设样本和特征数分别为  $n$  和  $m$  的信号数据集  $D = \{(\mathbf{X}_r, y_r)\} (\mathbf{X}_r \in R^m, y_r \in R, r = 1, 2, \dots, n)$ ,  $y_r$  和  $\mathbf{X}_r$  分别为样本状态标签、样本的特征向量,  $R^m$  表示所有  $m$  维特征向量的集合。集成决策树的模型表示为

$$\begin{cases} \hat{y}_r = \sum_{s=1}^K f_s(\mathbf{X}_r), f_s \in F \\ F = \{f_s(\mathbf{X}) = \omega_{s, q_s(\mathbf{X})}\} \\ (q_s : R^m \rightarrow \{1, 2, \dots, T\}, \omega_s \in R^T) \end{cases} \quad (7)$$

式中:  $\hat{y}_r$  为第  $r$  个样本的预测值;  $K$  为集成模型中的决策树数量;  $T$  为决策树的叶子节点数量;  $F$  为决策树集合;  $f_s$  表示第  $s$  棵决策树;  $f_s(\mathbf{X}_r)$  为第  $s$  棵树中  $\mathbf{X}_r$  的叶子权重;  $q_s(\mathbf{X}_r)$  为将  $\mathbf{X}_r$  映射到第  $s$  棵树中叶子节点的索引函数;  $\omega_{s, q_s(\mathbf{X}_r)}$  为第  $s$  棵树中相应叶子节点的权重值;  $\omega_s$  为第  $s$  棵树的叶子权重向量;  $R^T$  为叶子权重向量集合。LightGBM 的目标函数由损失函数(二分类对数损失函数)和正则化项两部分组成, 表达式为

$$\begin{cases} O_{bj} = \sum_{r=1}^n l(y_r, \hat{y}_r) + \sum_{s=1}^K \Omega(f_s) \\ \Omega(f_s) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T \omega_{s,j}^2 \end{cases} \quad (8)$$

式中:  $l(y_r, \hat{y}_r)$  为第  $r$  个样本的损失函数, 衡量实际值  $y_r$  与预测值  $\hat{y}_r$  之间的差异;  $\Omega(f_s)$  为第  $s$  棵树的正则化项, 防止过拟合;  $\gamma$  和  $\lambda$  表示控制模型复杂度的正则化参数;  $\omega_{s,j}$  为第  $s$  棵树中第  $j$  个叶子节点的权重。

为了更有效地优化目标函数, LightGBM 使用二阶泰勒展开来近似损失函数。在第  $t$  次迭代中, 目标函数的近似优化形式为

$$O_{bj}(t) = \sum_{r=1}^n \left[ g_r f_t(\mathbf{X}_r) + \frac{1}{2} h_r f_t^2(\mathbf{X}_r) \right] + \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T \omega_{s,j}^2 \quad (9)$$

式中:  $g_r$  为损失函数的一阶偏导数,  $g_r = \partial l(y_r, \hat{y}_r^{(t-1)}) / \partial \hat{y}_r^{(t-1)}$ ;  $h_r$  为二阶偏导数,  $h_r = \partial^2 l(y_r, \hat{y}_r^{(t-1)}) / (\partial \hat{y}_r^{(t-1)})^2$ 。在构建决策树时, LightGBM4 从当前所有叶子节点中选取增益最大的叶子来分裂, 分裂增益公式为

$$\Delta \mathcal{L} = \frac{G_L^2}{H_L + \lambda} + \frac{G_R^2}{H_R + \lambda} - \frac{(G_L + G_R)^2}{H_L + H_R + \lambda} - \gamma \quad (10)$$

式中:  $G_L$ 、 $H_L$  分别表示左叶子节点样本集合的一阶、二阶偏导数和;  $G_R$ 、 $H_R$  分别表示右叶子节点样本集合的一阶、二阶偏导数和。当  $\Delta \mathcal{L} > 0$  时, 分裂才被认为是有效的, 进而有选择地分裂叶子节点。

在寻找最优分割点过程中, 直方图方法将每个连续特征分成  $B$  个离散的区间, 构建等宽的直方图。利用预先计算的直方图统计量, 可以快速计算任意分裂点的偏导数和, 从而高效地计算分裂增益。此外 GOSS 和 EFB 算法在训练过程中能提取有效样本和降低特征层面的复杂度。前者基于梯度大小对样本进行筛选, 保留高梯度样本, 并对低梯度样本进行随机采样。后者通过合并满足冲突比率要求的

特征，以在减少特征数量的同时保证信息完整性。

### 3.2 诊断方法流程

基于干路电信号的 RF-LightGBM 电弧故障诊断算法流程见图 11，实现步骤如下。

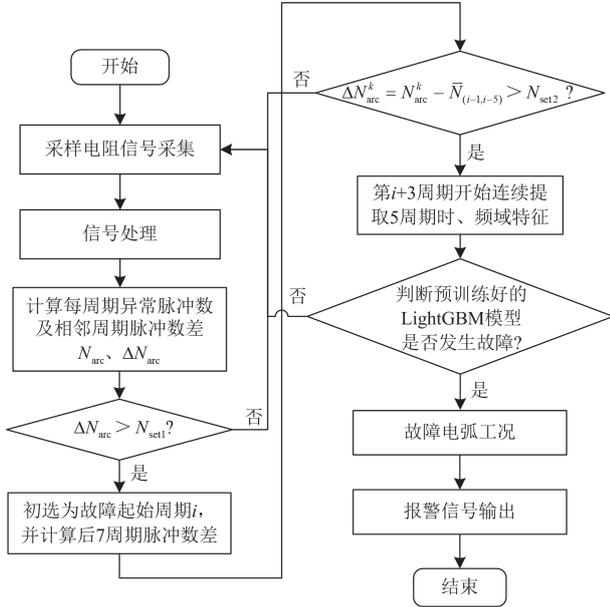


图 11 诊断方法流程

Fig. 11 Histogram algorithm diagram

**Step1:** 采集线路中干路电流流过采样电阻的电压信号，并经过低频衰减电路处理及剔除无效数据预处理。计算处理后信号每周期的异常脉冲数  $N_{arc}^k$  及相邻周期脉冲数差  $\Delta N_{arc}^k$ 。采样频率设置为 250 kHz。

**Step2:** 设双阈值  $N_{set1}$  和  $N_{set2}$ 。当  $\Delta N_{arc}^k > N_{set1}$  时，线路中可能产生故障电弧，将脉冲数首次发生突变的周期初选为故障发生起始周期  $i$ 。若从  $\Delta N_{arc}^k > N_{set1}$  后连续 7 周期内均出现故障与正常周期异常脉冲数差  $\Delta N_{arc}^k = N_{arc}^k - \bar{N}_{(i-1,i-5)} > N_{set2}$ ，将第  $i+3$  周期确定为识别起始周期，并进一步连续提取 5 个周期信号的时、频域特征：异常脉冲数、峰峰值、归零化峭度、偏度、波形因子、谱峭度标准差、3 和 5 次谐波幅值之和、总谐波失真率、功率谱熵、包络熵。

**Step3:** 提取故障初始周期及其后续周期的特征向量，并将其输入到预训练的 LightGBM 模型，识别是否存在串联故障电弧。在模型训练过程中，将样本集的特征矩阵和标签向量按照 8:2 的比例划分为训练集和测试集。将训练集数据输入 LightGBM 模型进行预训练，采用贝叶斯优化方法优化模型的超参数，并自动寻找最优参数组合，以提升模型性

能。将经过训练后的 LightGBM 模型应用于测试集进行电弧故障识别。

**Step4:** 对 LightGBM 模型识别出的电弧故障事件进行记录并报警。

为降低实际电弧诊断过程中的计算成本，同时减少因负载启动、负载功率变化等情况带来的误判。参考各工况下故障前后及各负载启动后异常脉冲数的变化情况，如图 12 所示。

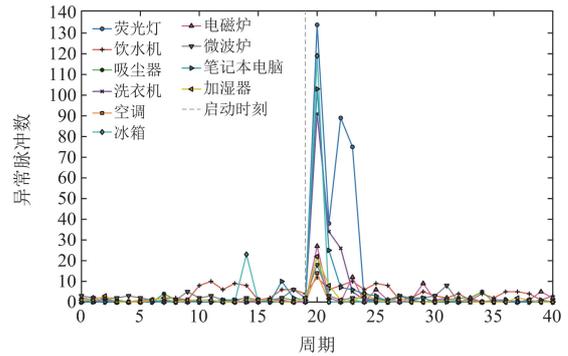


图 12 负载启动后异常脉冲数变化

Fig. 12 The number of abnormal pulses changes after load starting

设置  $N_{set1}$  为 10，用于捕捉故障电弧产生、负载启动或功率变化带来的脉冲数突变。设置  $N_{set2}$  为 5，作为连续 7 周期内  $\Delta N_{arc}^k > 5$  的确证阈值，确保识别持续性电弧故障并提升算法鲁棒性，抑制负载瞬态干扰。考虑到部分负载启动周期较长，从故障发生起始周期  $i$  后的第 3 周期开始，提取时频域特征。

## 4 实验室测试验证

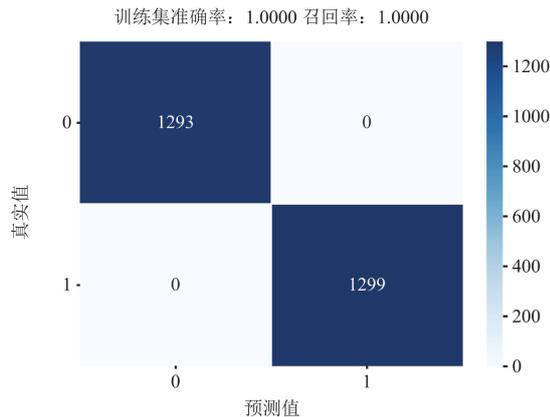
### 4.1 检测结果与分析

针对基于干路电信号的 RF-LightGBM 电弧故障诊断方法，本文选用召回率、准确率来量化该方法的分类效果。通过示波器采集故障放大电路处理后采样电阻两端的信号，样本数据包含 54 种工况，每种工况下均包含 30 组正常数据与 30 组故障数据，共计 3240 组样本数据。提取样本特征并通过 RF 进行特征筛选，构建故障电弧诊断特征数据集并进行划分，对 LightGBM 模型进行训练。鉴于超参数对模型性能影响显著，本文采用 Optuna 库中的贝叶斯优化算法来优化 LightGBM 模型的关键超参数。该方法旨在克服传统网格搜索在计算资源和时间效率上的不足，实现对 LightGBM 超参数的高效同步调优，以增强模型的分类准确性。设定超参数优化范围，选取的超参数见表 4。

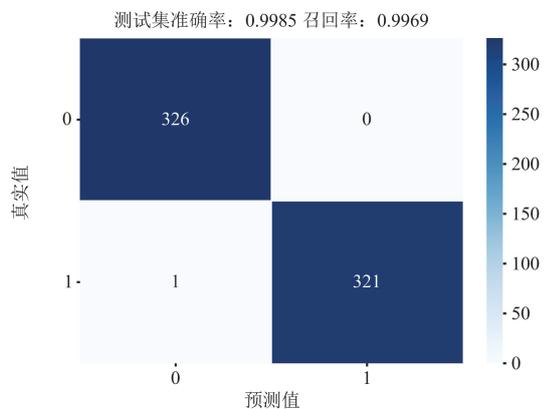
表 4 LightGBM 模型超参数  
Table 4 LightGBM model hyperparameters

超参数类别	优化范围	超参数选取
决策树数量(n_estimators)	[50,200]	114
树的最大深度(max_depth)	[4,10]	6
学习率(learning_rate)	[0.1,1]	0.9432
随机采样比例(subsample)	[0.5,0.8]	0.6
L2 正则化项参数(reg_lambda)	[0,1]	0.9
树的最大叶子节点数(num_leaves)	[1,1000]	681

LightGBM 电弧故障诊断模型检测结果如图 13 所示。可以看出训练集和测试集的诊断结果都较好, 训练集诊断的召回率和准确率均为 100%, 测试集诊断的召回率为 99.69%, 准确率为 99.85%。工况 46(全负载运行下回路 1 和 4 发生电弧)中, 有一组电弧故障数据被误判为正常。其原因是电弧燃烧不稳定, 导致信号在部分周期出现正常空档, 致使整体故障特征不明显。目前实验中每组样本时长为 100 ms, 而 GB 14287.4 规定, 若 1 s 内产生电弧故障时间为 7 个及以上周期时, 保护器需在 30 s 内发



(a) 训练集混淆矩阵



(b) 测试集混淆矩阵

图 13 LightGBM 模型的混淆矩阵

Fig. 13 Confusion matrix of LightGBM model

出报警信号。后续可在实际应用中适当延长检测周期, 降低漏报率及误报率。综上所述, 本文提出的 RF-LightGBM 干路电弧故障诊断方法, 能有效应对多种复杂工况。该模型具备较高的诊断准确率和强大的泛化能力, 同时在干路诊断中保持了较低的误判率。

## 4.2 消融实验

### 4.2.1 检测方法对比

为了验证基于干路电信号的 RF-LightGBM 电弧故障诊断模型及低频衰减电路的有效性。本文针对原始及低频衰减后的采样电阻电压信号, 在 54 种工况下, 对比评估了 5 种分类方法的准确率与平均训练时长。其中电脑配置环境为 Intel(R) Core(TM) i5-9300H CPU @ 2.40 GHz, 2400 MHz。

由表 5 可知, 经低频衰减电路处理后, 各模型的故障电弧诊断准确率均达 98% 以上, 性能较处理前显著提升, 验证了该电路的有效性。在各模型中, LightGBM、XGboost 和 RF 模型的故障识别能力较强, 但相比 SVM 和 KNN 的平均训练时长有所增加。其中, 在原始采样电阻电压信号与处理后信号条件下, LightGBM 模型的准确率分别为 95.57%、99.85%, 平均训练时长均为 0.7 s 左右。从整体效果来说, 基于低频衰减后的 RF-LightGBM 模型保持较高的电弧故障诊断准确率, 且模型训练时间较短。

表 5 各诊断模型测试结果

Table 5 Test results of each diagnostic model			
诊断模型	数据	准确率/%	平均训练时长/s
SVM	处理前信号	91.67	0.03
	处理后信号	98.46	0.06
RF	处理前信号	95.99	3.29
	处理后信号	99.54	3.27
KNN	处理前信号	93.72	0.1
	处理后信号	98.77	0.08
XGboost	处理前信号	94.96	1.3
	处理后信号	99.07	1.1
LightGBM	处理前信号	95.57	0.75
	处理后信号	99.85	0.71

### 4.2.2 其他工况测试

为了验证该电弧诊断方法在未知配电场景下的检测效果, 本文考虑其他易带来干扰的非线性负载: 调光灯(共 600 W, 12 个)、手持电钻(800 W)、开关电源(690 W)。仍使用采样电阻进行采样并进行低频衰减处理, 正常、故障样本各 30 组, 测试结果如表 6 所示, 平均准确率达 98.89%。其中工况 1、4、5 受调光灯高频噪声影响出现少量误报, 其余准确率均为 100%, 表明所提方法在复杂配电场景下具有

较强的鲁棒性与泛化能力。工况 1 和工况 5 的电弧信号波形如图 14 所示。

表 6 其他工况测试结果

Table 6 Other conditions test results

工况	准确率/%	工况	准确率/%
1 调光灯	98.33	4 调光灯 + 手持电钻	98.33
2 手持电钻	100	5 调光灯 + 开关电源	96.67
3 开关电源	100	6 手持电钻 + 开关电源	100

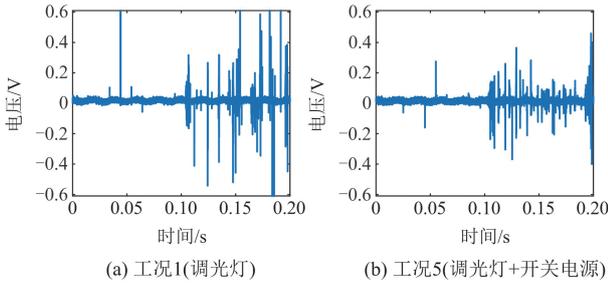
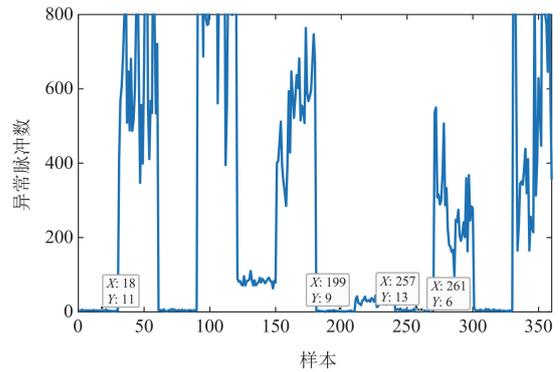


图 14 工况 1、5 的电弧信号波形

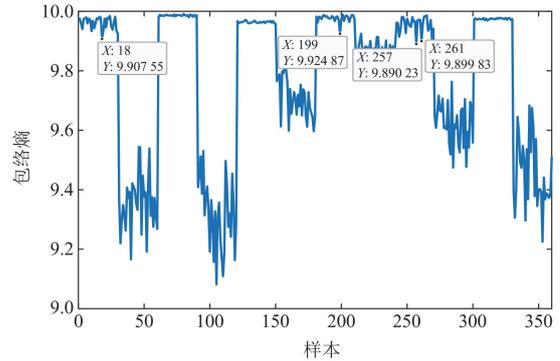
Fig. 14 Arc signal waveforms for operating conditions 1 and 5

可以看出调光灯在正常运行期间，其电流信号存在幅值不规律的异常脉冲，但大部分周期异常脉冲都比较稀疏，脉冲密度显著低于发生电弧的情况，且正常运行时波形相对稳定。对 6 种工况下的信号进行电弧特征值计算，异常脉冲数、包络熵特征结果如图 15 所示。异常脉冲数特征对调光灯噪声表现出较强鲁棒性，但对开关电源干扰较为敏感——后者在正常工况下亦会产生大量脉冲，导致特征区分度下降。相比之下，包络熵特征受调光灯影响显著：调光灯正常运行时会导致包络熵值异常降低，使其特征分布与故障状态产生重叠，进而引发误报。此外，其余所选特征在调光灯干扰下的性能也表现欠佳，还有待于进一步优化。

为验证检测模型的抗噪性能，引入不同信噪比 (signal-to-noise ratio, SNR) 的高斯噪声进行鲁棒性评估。针对不同工况，从其正常组数据中提取并生成相应的噪声，通过向正常与故障组数据叠加 SNR 为 -10~10 dB 的高斯噪声，并在此基础上进行故障诊断。当 SNR 降至 -10 dB 时，诊断准确率均有较大幅度降低，其中工况 5(调光灯 + 开关电源)的准确率降至 46.67%，故障特征被噪声严重掩盖；而在临界噪声水平(SNR 为 0 dB)下，各工况准确率均高于 80%，表明模型具有较好的噪声鲁棒性。进一步分析特征敏感性发现异常脉冲数、功率谱熵及包络熵易受高斯噪声干扰，其他特征不太敏感，而归零化峭度、偏度及 3 和 5 次谐波幅值之和则对调光灯负载扰动敏感。引入小波阈值降噪后，在含调光灯的



(a) 异常脉冲(从左到右为工况1—工况6)



(b) 包络熵(从左到右为工况1—工况6)

图 15 消融实验 2 中各工况的特征图

Fig. 15 Characteristic diagrams of various operating conditions in ablation experiment 2

工况下，故障诊断准确率在 SNR 为 0 dB 时可提升到 90%以上。后续研究将优化特征提取，探索与负载无关的强鲁棒性故障电弧特征，并引入更有效的降噪方法，以进一步提升检测方法的抗噪性与准确性。

此外本文同其他文献对比，涉及负载类型来源、工况数更多：文献[20](负载 6 种，工况 9 种)、文献[21](负载 6 种，工况 9 种)、文献[22](负载 7 种，工况 7 种)、文献[28](负载 13 种，工况 18 种)、文献[29](负载 6 种，工况 28 种)、本文(负载 13 种，工况 60 种)。不同于上述文献通过电流互感器来提取电流信号，采样电阻电压信号也易于获取，且在不同工况下呈现一定的规律性，可为多负载、多支路场景下的串联故障电弧诊断提供参考。

### 5 结论

本文针对低压交流串联故障电弧，提出了一种基于干路电信号的 RF-LightGBM 故障电弧诊断方法，通过设计搭建多负载、多支路的电弧实验平台，提取了 54 种工况下的正常、故障样本数据进行检测，并设计消融实验进行验证，得到如下结论。

1) 由于多负载电路的电流信号差异性导致串联电弧诊断困难, 本文分析发现电流流过的采样电阻电压信号在单/多负载运行工况下存在一定规律性, 其时域波形中的电弧特征均呈现脉冲尖峰形态, 有利于实现未知复杂配电环境下的干路电弧诊断。

2) 针对部分小功率负载产生的电弧故障信息易淹没在干路电流中的情况, 本文设计了一个简单的低频信号衰减电路, 通过降低低频信息来凸显高频的故障特征, 对比了多工况下的处理结果, 故障信号时域波形中的脉冲尖峰均明显增多。

3) 对处理后的采样电阻信号提取多种时频域特征, 并采用 RF 方法对特征进行筛选, 确定重要性前 10 的特征, 将 54 种工况下的特征数据集输入经贝叶斯优化的 LightGBM 模型进行故障诊断, 测试集的电弧诊断准确率达到 99.85%, 未知工况下准确率在 96.67% 以上。

本文提出的交流串联电弧故障诊断方法在多种单负载、多负载工况下可以实现良好的诊断效果和泛化性能。考虑到电弧故障特性会受环境湿度、温度等因素的影响, 受限于实验条件, 本文未对上述情况进行试验验证, 可在后续工作中进一步分析。

#### 参考文献

- [1] 肖方. 今年 1-10 月全国火灾形势分析[J]. 中国消防, 2023: 28-29.
- [2] 秦译为, 张蓬鹤, 宋如楠, 等. 新型电力系统下电弧故障诊断技术及发展趋势[J]. 电测与仪表, 2024, 61(2): 1-9.  
QIN Yiwei, ZHANG Penghe, SONG Runan, et al. Arc fault diagnosis technology and trends of development in new power system[J]. Electrical Measurement & Instrumentation, 2024, 61(2): 1-9.
- [3] 胡伟, 杨帆, 雷杨, 等. 基于电压暂降特征与 Hausdorff 距离算法的串联电弧故障检测方法[J]. 供用电, 2024, 41(6): 64-74.  
HU Wei, YANG Fan, LEI Yang, et al. Series arc fault detection method based on voltage sag feature and Hausdorff distance algorithm[J]. Distribution & Utilization, 2024, 41(6): 64-74.
- [4] 刁晓虹, 董昊, 侯磊, 等. 基于 CEEMDAN-HT 和 SAE 的直流故障电弧诊断方法研究[J]. 电网与清洁能源, 2023, 39(10): 1-8, 18.  
DIAO Xiaohong, DONG Hao, HOU Lei, et al. Research on the DC fault arc detection method based on CEEMDAN-HT and SAE[J]. Power System and Clean Energy, 2023, 39(10): 1-8, 18.
- [5] 汪洋堃. 低压交流电弧的动态特性与故障检测方法研究[D]. 上海: 上海交通大学, 2020.  
WANG Yangkun. Research on dynamic characteristic and fault diagnostic method for low voltage AC arcing[D]. Shanghai: Shanghai Jiao Tong University, 2020.
- [6] 陈新美, 魏超, 刘园伟, 等. 电弧光保护原理分析及其校验测试设备的研发应用[J]. 电力系统保护与控制, 2019, 47(14): 160-165.  
CHEN Xinmei, WEI Chao, LIU Yuanwei, et al. Analysis of electric arc flash protection principle and development application of its standard calibration equipment[J]. Power System Protection and Control, 2019, 47(14): 160-165.
- [7] 周林, 曹天怡. 电弧光保护作为母线主保护在中低压开关柜的应用和讨论[J]. 供用电, 2016, 33(12): 47-53, 57.  
ZHOU Lin, CAO Tianyi. Applications and discussions of arc flash protection relay as a main busbar protection in MV/LV switchboards[J]. Distribution & Utilization, 2016, 33(12): 47-53, 57.
- [8] KE Y, ZHANG W, SUO C, et al. Research on low-voltage AC series arc-fault detection method based on electromagnetic radiation characteristics[J]. Energies, 2022, 15(5).
- [9] WU N, PENG M, WANG J, et al. Research on voltage-current type series arc fault detection method based on composite multi-scale entropy[J]. Electric Power Systems Research, 2025, 242: 111445.
- [10] DAI W, ZHOU X, SUN Z, et al. Series AC arc fault detection method based on L2/L1 norm and classification algorithm[J]. IEEE Sensors Journal, 2024, 24(10): 16661-16672.
- [11] GONG Q, PENG K, ZHANG X, et al. Low-voltage AC series arc fault detection method based on similarity measure between differential arc voltage and square wave[J]. IEEE Transactions on Instrumentation and Measurement, 2025, 74: 1-17.
- [12] WANG Y, HOU L, PAUL K C, et al. ArcNet: series AC arc fault detection based on raw current and convolutional neural network[J]. IEEE Transactions on Industrial Informatics, 2022, 18(1): 77-86.
- [13] TAN M, GONG Y, WANG L, et al. LFarc-PFE: a series arc fault detection method based on low-frequency current data and perturbation feature extraction[J]. IEEE Transactions on Instrumentation and Measurement, 2025, 74: 1-11.
- [14] 刘浩宇, 刘挺坚, 刘友波, 等. 基于图卷积神经网络的直流送端系统暂态过电压评估[J]. 电力系统保护与控制, 2023, 51(23): 71-81.  
LIU Haoyu, LIU Tingjian, LIU Youbo, et al. A method for evaluating transient overvoltage of an HVDC sending-end system based on a graph convolutional network[J]. Power System Protection and Control, 2023, 51(23): 71-81.
- [15] CHABERT A, BAKKAY M C, SCHWEITZER P, et al. A transformer neural network for AC series arc-fault detection[J]. Engineering Applications of Artificial

- Intelligence, 2023, 125.
- [16] LIU H, LI J, WANG W, et al. Arc-1DCNN: an enhanced model for series arc fault detection[J]. Measurement, 2024, 234.
- [17] 李莉, 黄友金, 熊炜, 等. 基于改进卷积神经网络的非侵入负荷辨识方法研究[J]. 电测与仪表, 2024, 61(1): 125-130.  
LI Li, HUANG Youjin, XIONG Wei, et al. Non-intrusive load identification method based on improved convolutional neural network[J]. Electrical Measurement & Instrumentation, 2024, 61(1): 125-130.
- [18] 陈泰龙, 马玫, 陈少磊, 等. 基于多尺度优化卷积神经网络的配电网电缆局部放电图像识别[J]. 供用电, 2023, 40(11): 105-111.  
CHEN Tailong, MA Mei, CHEN Shaolei, et al. Cable fault diagnosis of distribution network based on multi-scale optimized convolutional neural network[J]. Distribution & Utilization, 2023, 40(11): 105-111.
- [19] 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.
- [20] 王毅, 刘黎明, 李松浓, 等. 基于经验小波变换复合熵值与特征融合的故障电弧检测[J]. 电网技术, 2023, 47(5): 1912-1919.  
WANG Yi, LIU Liming, LI Songnong, et al. Arc fault detection based on empirical wavelet transform composite entropy and feature fusion[J]. Power System Technology, 2023, 47(5): 1912-1919.
- [21] 罗晨, 喻锬, 曾祥君, 等. 基于高频重构信号与 Bayes-XGBoost 的低压电弧故障辨识方法研究[J]. 电力系统保护与控制, 2023, 51(13): 91-101.  
LUO Chen, YU Kun, ZENG Xiangjun, et al. Low voltage arc fault identification method based on high frequency reconstructed signal and Bayes-XGBoost[J]. Power System Protection and Control, 2023, 51(13): 91-101.
- [22] 江永鑫, 陈丽安, 郭梦倩, 等. 基于改进 CEEMD 和 RF 的低压串联故障电弧识别方法[J]. 电力系统保护与控制, 2024, 52(1): 97-108.  
JIANG Yongxin, CHEN Lian, GUO Mengqian, et al. Identification method of low voltage series fault arc based on improved CEEMD decomposition and RF[J]. Power System Protection and Control, 2024, 52(1): 97-108.
- [23] 周纲, 黄瑞, 刘谋海, 等. 基于变分模态分解和复合变量选取的短期负荷预测[J]. 电测与仪表, 2024, 61(2): 122-129.  
ZHOU Gang, HUANG Rui, LIU Mouhai, et al. Short-term load forecasting based on variational mode decomposition and complex variable selection algorithm[J]. Electrical Measurement & Instrumentation, 2024, 61(2): 122-129.
- [24] CHU R, SCHWEITZER P, ZHANG R. Series AC arc fault detection method based on high-frequency coupling sensor and convolution neural network[J]. Sensors, 2020, 20(17).
- [25] 鲍光海, 江润. 基于磁通不对称分布的串联电弧故障检测研究[J]. 仪器仪表学报, 2019, 40(3): 54-61.  
BAO Guanghai, JIANG Run. Research on series arc fault detection based on asymmetrical distribution of magnetic flux[J]. Chinese Journal of Scientific Instrument, 2019, 40(3): 54-61.
- [26] JIANG R, ZHENG Y. Series arc fault detection using regular signals and time-series reconstruction[J]. IEEE Transactions on Industrial Electronics, 2023, 70(2): 2026-2036.
- [27] 耿闻昊. 低压交流串联电弧故障检测技术研究[D]. 哈尔滨: 哈尔滨工业大学, 2022.  
GENG Wenhao. Research on detection technology of low-voltage series AC arc fault[D]. Harbin: Harbin Institute of Technology, 2022.
- [28] 巩泉役, 彭克, 陈羽, 等. 基于电弧随机性和卷积网络的交流串联电弧故障识别方法[J]. 电力系统自动化, 2022, 46(24): 162-169.  
GONG Quanyi, PENG Ke, CHEN Yu, et al. Identification method of AC series arc fault based on randomness of arc and convolutional network[J]. Automation of Electric Power Systems, 2022, 46(24): 162-169.
- [29] 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.
- [30] KE G, MENG Q, FINLEY T, et al. Lightgbm: a highly efficient gradient boosting decision tree[J]. Advances in Neural Information Processing Systems, 2017, 30.

收稿日期: 2024-12-28; 修回日期: 2025-06-24

作者简介:

薛阳(1987—), 男, 硕士, 教授级高级工程师, 主要研究方向为反窃电技术、计量设备故障诊断等; E-mail: xueyang3@epri.sgcc.com.cn

陈少雄(1999—), 男, 通信作者, 硕士研究生, 研究方向为泄漏电流检测及交流故障电弧诊断。E-mail: c3202272090@163.com

(编辑 许威)