doi:10.3772/j.issn.1002-0470.2023.11.009

# 基于 OS-EM-ELM 的边缘侧串联电弧故障检测方法<sup>①</sup>

薛 鹏② 潘国兵③ 欧阳静 陈星星

(浙江工业大学机械工程学院 杭州 310023)

摘要 电弧故障的高度随机性、复杂性使得其难以被准确识别。针对传统电弧识别算法对硬件算力要求高、实时性较低且一旦固定无法更改的问题,提出一种适用于边缘计算、多负载种类和多特征结合的误差最小化极限学习机(EM-ELM)电弧故障检测方法。通过快速傅里叶变换(FFT)、db4 小波分解,提取周期均值差、脉宽百分比、间谐波因数及小波高频能量,作为边缘侧电弧故障检测算法的输入特征。在此基础上提出结合在线序列(OS)方法的 OS-EM-ELM 方法,运用现场运行数据对算法进行改进,提高适应性。实验结果表明,所提方法能有效地区分正常和电弧故障的波形,且适用于多种类型负载同时工作的复杂情况,计算量小,可实现在线训练,适应性强,应用成本低,更加符合电弧检测装置边缘计算的要求。

关键词 交流(AC)串联电弧;边缘侧;快速傅里叶变换(FFT);故障识别;极限学习机 (ELM)

# 0 引言

随着电力工业发展,用电设备不断增加,低压配 电系统的规模和容量不断扩大,同时配电网络中超 期服役的电气不断增加,由电气引发火灾的风险也 在增加<sup>[1]</sup>。电弧故障又是引起电气火灾的主要起 因之一,现有的空气开关等保护措施无法对电弧故 障产生保护动作。电弧故障识别技术是低压配电线 路防护系统中重要的新型保护技术。交流串联电弧 故障随机性高,故障检测会受电路中不同类型的负 载影响,使得电弧故障识别变得困难。同时电弧故 障识别装置安装在配电网络的末端,既要在边缘侧 独立完成数据采集、分析、识别,又要保证准确、快速 地识别串联电弧故障并对电路进行有效保护是低压 配电线路中急需解决的问题<sup>[2]</sup>。

近几年,国内外主要研究者提出的电弧故障识

别技术包括电弧数学模型、电弧物理特性、电弧电流 电压波形以及智能化电弧识别。这4种电弧故障识 别技术各有优缺点,应用场合也不同。最早提出的 电弧数学模型是 Cassie 黑盒电弧模型<sup>[3]</sup>和 Mavr 电 弧模型<sup>[4]</sup>。在此基础上,研究者提出了 Schavemaker 模型<sup>[5]</sup>、Habedank 电弧模型<sup>[6]</sup>、Schwarz 电弧模 型<sup>[7]</sup>、Stokes 电弧模型<sup>[8]</sup>等。刘艳丽等人<sup>[9]</sup>建立了 神经网络黑匣子模型,并进行仿真分析,用于不适合 开展现场试验电弧故障检测场景。徐秦乐等人<sup>[10]</sup> 提出采集声、光和温度传感器数据的融合算法,克服 了单传感器的不确定性,但多个传感器的布置造成 硬件成本增加。丁鑫等人<sup>[11]</sup>进行频谱分析,提取基 于谐波含量分析的3个特征值。蔡杰轩<sup>[12]</sup>提出基 于5次谐波分量的电弧故障识别方法,但该方法用 单一的谐波含量进行识别,误报率相对较高,抗干扰 能力较弱。缪希仁等人[13]提出检测负载端电压的

 通信作者, E-mail:gbpan@zjut.edu.cn。 (收稿日期:2022-02-28)

① 国家重点研发计划(2017YFA0700301),浙江省重点研发计划(2021C01112)和浙江省基础公益技术研究计划(No. LGF21E070001)资 助项目。

② 男,1996年生,硕士生;研究方向:分布式能源与微电网;E-mail:2111902062@zjut.edu.cn。

新方法,但负载端的电压波形收集会受到电弧发生 位置的影响,电压采集模块的放置困难。佟为明等 人<sup>[14]</sup>提出基于计算小波高频分量的周期方差值电 弧检测方法,并将算法移植到单片机中,但只针对一 些单一负载进行识别。Han 等人<sup>[15]</sup>针对电源谐波 和非线性负载噪声的干扰,提出基于核主成分分析 (kernel principal components analysis, KPCA) 和萤火 虫算法优化支持向量机(firefly algorithm support vector machine, FA-SVM)的识别方法,适用一些工业领 域的交流串联电弧,但计算量大。苏晶晶等人<sup>[16]</sup>基 于混沌分形理论,建立基于电弧空间域特征向量和 概率神经网络(probabilistic neural network, PNN)的 诊断模型,但不适合应用在边缘侧等算力有限的场 景中。张丽萍等人<sup>[17]</sup>对比了极限学习机(extreme learning machine, ELM)、误差逆向传播(back propagation, BP) 神经网络和支持向量机(support vector machine.SVM)方法,在电弧识别上的结果,得出了 ELM 算法训练相对较优的结论。

综上,在实际的复杂电气环境中,目前提出的识 别算法存在只能识别单一负载或者由于算法复杂、 计算量增大、对硬件要求提高、模型固定因而无法在 边缘侧进行适应性训练的情况。而电弧识别装置要 想在实际环境中安装和应用就不得不考虑装置成本 和计算能力问题。

因此,综合考虑边缘计算硬件的算力要求和实际运行中不同类型负载同时工作的情况,本文兼顾时域和频域,提取周期均值差、脉宽百分比、间谐波因数及小波高频能量这4个特征,提出基于在线序列(online sequential,OS)-误差最小(error minimization, EM)-极限学习机(ELM),即OS-EM-ELM算法的边缘侧电弧故障检测方法进行故障检测,引入在线序列训练方法来提高电弧识别在复杂电气环境下的适应性。实例证明,该方法具有计算量小、适应能力强、识别精度高的特点,可供电弧故障检测研究人员参考。

1 交流串联电弧故障波形采集

#### 1.1 电弧故障波形采集平台

为获取电弧故障的电流数据用于特性分析与实

验验证,搭建一个低压串联电弧故障实验平台,采集 不同负载、不同电流等级下电弧故障和正常运行的 电流信号。根据 GB 14287.4 标准搭建低压串联电 弧故障的实验平台和装置,如图1所示。



图1 交流串联电弧故障实验平台装置图

低压串联电弧故障的实验平台主要包括:220 V 的交流电源、各类不同负载、空气开关、电流传感器、 波形采集器和点接触电弧发生器。

点接触电弧发生器由一个可移动的铜电极、一 个静止的碳电极以及相应的绝缘件组成。实验时先 让动、静电极良好接触模拟正常工作状态,然后控制 动、静电极分离,直至产生串联故障电弧。文中有关 的电弧实验原始数据均由此装置采集。

## 1.2 电弧故障采集方案

由于在日常生活中的用电器绝大多数是阻感性的,为模拟现实条件下的负载特性,按表1选取实验 负载进行实验,并组建交流串联电弧故障数据库。

表1 采集负载类型及额定功率

负载类型	负载	额定功率
	电阻 1	500 W
阻性负载	电阻 2	1000 W
	电水壶	1500 W
	吸尘器	600 W
感性负载	日光灯	36 W
	电机	1000 W
	电吹风中档位	600 W
阻感性负载	电吹风高档位	1200 W
	上述负载的组合	/

#### 1.3 采集结果与分析

为选取合适的特征参数,需要对阻性、感性、阻 感性负载波形特性进行研究。以阻性负载电水壶、

— 1214 —

感性负载吸尘器及阻感性负载电吹风 + 电机为例, 具体分析电弧电流特性。

(1) 阻性负载

从电弧故障数据库分别取出电水壶正常运行和 电弧故障的电流波形如图 2 所示,图 2 左侧为正常 波形。对比分析发现,阻性负载电水壶在正常工作 时的电流波形光滑;电弧故障时,电流在零点附近有 明显平肩部,即"零休"现象,而且每个周期都反复 出现,且电流的幅值比正常时低。其他阻性负载例 如纯电阻、白炽灯等都有类似的特点。



图 2 阻性负载电水壶正常运行和电弧故障时的电流波形

(2) 感性负载

吸尘器在正常运行状态和电弧故障时的电流波 形分别如图 3 所示,图 3 左侧为正常波形。通过对 比分析发现,吸尘器在正常运行时的电流波形近似 于三角,具有周期性。吸尘器电弧故障时,在零点附 近有明显的平肩部,电流波形有大量的毛刺。



图 3 感性负载吸尘器正常运行和电弧故障时的电流波形

#### (3) 阻感性组合负载

阻感性负载选用电机和电吹风的组合,两者的 功率相差不大。电吹风的绝大多数的功率消耗在电 阻丝发热上,因此作为阻性负载来源。电吹风和电 机在正常运行时和电弧故障时的电流波形如图4所 示,图4左侧为正常波形。通过对比可观察到阻感 性负载正常运行时的电流波形光滑具有周期性。而 电弧故障时,每个周期2次过零点的附近都有较长时间的平肩部,而且每个周期平肩部持续的长短相差较大。每个周期的幅值变化很明显。



图 4 阻感性电吹风 + 电机正常运行和电弧故障时电流波形

经过上述对比分析可以发现以下现象。

(1)电弧故障时,电流在零点附近会产生"零休" 现象,每次过零点前电弧都会暂时熄灭,之后极间电 压升高,电弧再次点燃。这种点燃熄灭交替的现象每 半周期出现一次,在电流上表现为平肩部,并且伴随 着大量毛刺,这是电弧故障最重要的特征之一。

(2)虽然不同类型的负载正常运行时电流波形 不尽相同,但每个周波都具有周期性,前后一致性 高。电弧故障时,前后波形一致性降低。

(3)电弧故障时的电流幅值一般要比正常时的 电流幅值小,这是因为电弧燃烧需要击穿电极间的 空气介质,使得线路总阻抗增大。同时有些负载启 停缓慢,在惯性的影响下,在故障时会出现幅值不停 波动的现象。

(4)电弧故障时,电流波形明显发生畸变,在平 肩部的拐点处有明显的毛刺,且容易产生高频尖峰, 在感性负载中尤为明显。

2 特征量提取与有效性分析

#### 2.1 周期均值差

电弧电流特性分析中可知正常运行的负载电流 波形一般都具有周期性,而电弧故障时的电流波形 没有呈现明显的周期性现象。针对这一特性提取电 流周期均值差,以一个周期为单位,计算每个周期采 样点的均值,后一个周期均值减去前一个周期均值 得到周期均值差。计算过程如下。

(1) 假设每个周期采样点数为 N, 每个采样点— 1215 —

的电流值用 i 来表示,那么相邻的 2 个电流值就是  $i_k, i_{k-1}$ ,电流的平均值用  $I_{aver}$ 表示。

$$I_{\text{aver}} = \frac{\sum_{k=1}^{N} |i(k)|}{N}$$
(1)

(2) 相邻周期均值差用 I<sub>sub</sub> 表示。

$$I_{\text{sub}} = |I_{\text{aver}(k)} - I_{\text{aver}(k-1)}|$$
(2)

从建立的电弧数据库中分别取出正常运行和电 弧故障的电流波形数据,每种负载取100个样本。 以一个周期为单位,分别计算正常运行和电弧故障 相邻周期的均值差,并对计算结果求均值。

表2反映了不同负载在正常和故障时具体的波动范围,可观察到负载在不同状态下周期均值差存 在数量级上的区别。可见周期均值差是一个反映电 弧的时域特征的较好特征。

表 2 不同负载在正常和故障状态下周期均值差的波动范围

负载	正常运行范围	电弧故障范围
电水壶	0.0025 ~ 0.0030	0.0329 ~0.2517
吸尘器	0.0003 ~0.0043	$0.0142 \sim 0.0741$
日光灯	$0.0005 \sim 0.0094$	$0.0042 \sim 0.0162$
开关电源	$0.0003 \sim 0.0031$	$0.0062 \sim 0.0424$
电吹风 + 电机	$0.0161 \sim 0.0623$	$0.4602 \sim 2.4020$

## 2.2 脉宽百分数

在交流线路中发生电弧故障时,电弧由于其放 电特性在零点附近出现"零休"现象。电弧故障时 电流幅值会有比较长的一段时间在零点附近。根据 此特性可以用它判断电弧故障是否发生。脉宽百分 数的计算步骤为:

(1) 获取离散波形信号, 以 $\{x_1, x_2, \dots, x_N\}$ 表示。

(2)对信号取绝对值即 {| x<sub>1</sub>|, | x<sub>2</sub>|,..., | x<sub>N</sub>|}。
 归一化处理,并统计集合内在 k<sub>1</sub>、k<sub>2</sub> 之间的元素的
 个数 n。

(3)计算 n 所占样本周期内所有点的比重,即 Z = (n/N) × 100%。

经过实验和分析波形数据,综合选取  $k_1 = 0.005, k_2 = 0.5$ 。按上述计算步骤,对热水壶+吸尘器的正常和故障的波形数据进行计算,获得结果如

图 5所示。从图中可以看出,脉宽百分数能对不同 运行状态进行区分,故该参数可以作为边缘侧电弧 识别的一个有效特征。



# 2.3 部分间谐波因数

从频域方面考虑,电弧故障时时域波形发生畸变,频域也会产生变化。部分间谐波因数是采样波形经快速傅里叶变换(fast Fourier transform, FFT) 后,相对于基频非整数倍的部分间谐波幅值跟基频的幅值之比,取 $f_k = 25 \times (2k - 1)$ 。计算公式为

$$h_k = \frac{I_{2k-1}}{I_0} \qquad k = 1, 2, \cdots, 13$$
 (3)

其中, $I_{2k-1}$ 为k次间谐波幅值, $I_0$ 为基频幅值, $h_k$ 是 k次间谐波因数。为确定k的合适取值,对数据库 中的波形数据进行分析。

阻感性负载的正常运行和电弧故障的间谐波因 数如图6所示。正常时的间谐波因数几乎没有变



图 6 阻感性负载波形间谐波因数图

化,在零点附近徘徊,故障时1、2次间谐波因数发生 较大变化,之后逐渐降低。数据库中其他类型的负 载也有相同的趋势,故提取第1、2次的间谐波因数 作为识别电弧的频域特征。

## 2.4 小波高频分量的能量

从电弧电流特性分析中可知电弧电流波形在平 肩末端的阶跃拐点处有明显的毛刺,且出现尖峰。 针对这一特性对电流信号进行小波分解重构,观察平 肩末端的阶跃拐点和尖峰处高频分量的分布情况。

以阻性负载电水壶为例,分别取出正常运行时 和电弧故障时电流信号数据,归一化处理之后,用 db4 进行小波 3 层的分解和重构。电水壶正常运行 和电弧故障的小波分解重构如图 7 所示,电弧故障 时的 d1、d2、d3 这 3 层小波高频分量明显比正常运 行时大,电弧电流波形在平肩末端的拐点处有明显 的高频成分。d2 层的小波高频分量相较于 d1、d3 能 更好地区分 2 种状态。



图 7 电水壶正常运行和电弧故障的小波分解重构图

感性负载吸尘器、阻感性负载电吹风 + 电机等 等也都有类似的特点。d2 层小波高频分量的能量计 算公式为

$$P = \sum_{n=0}^{N} (d_2(n))^2$$
 (4)

式中, N 为每周期的采样点数, d<sub>2</sub>(n) 为小波分解 第2 层的小波高频分量。

不同负载正常运行和电弧故障小波高频分量的 周期能量对比如图 8 所示。电弧故障小波高频分量 的周期能量可以有效区分正常运行和电弧故障这2 种状态,可以作为电弧故障识别的特征。



3 边缘侧串联电弧故障识别算法研究

## 3.1 极限学习机

在边缘计算领域,算力是十分有限的资源。极 限学习机(ELM)作为一种机器学习算法,在标签分 类领域有广泛的应用,其网络结构示意图如图9所 示。极限学习机只有一层隐含层,隐含层节点数影 响准确度和计算量。

得益于 ELM 的随机化权值和偏置,极限学习机 的训练速度比传统神经网络(如 BP 算法)速度快百 倍之多。综合分析算力与精度,极限学习机算法十 分适合在边缘侧应用。



#### 3.2 误差最小化改进极限学习机

不同于传统 ELM 人为规定隐含层节点个数,误

— 1217 —

差最小化极限学习机(error minimized ELM, EM-ELM)模型通过构造法逐步添加隐含层节点个数,通 过误差最小化的方法确定最优解。EM-ELM 训练分 为2个阶段。

初始化阶段构造一个具有  $L_0$  个隐含节点的前 馈神经网络,选取电弧故障数据库  $N_0$  组数据,随机 产生输入权值矩阵  $w_i$ ,偏置矩阵  $b_i$ ,给定激活函数  $f(x),其中 i = 1,2,...,\tilde{N}, N_0 \ge \tilde{N}_0$ 矩阵公式如下:  $H_0 =$  $\begin{bmatrix} f(w_1x_1 + b_1) & f(w_2x_1 + b_2) & \cdots & f(w_{\tilde{N}}x_1 + b_{\tilde{N}}) \\ f(w_1x_2 + b_1) & f(w_2x_2 + b_2) & \cdots & f(w_{\tilde{N}}x_2 + b_{\tilde{N}}) \\ \vdots & \vdots & \vdots \\ f(w_1x_{N_0} + b_1) & f(w_2x_{N_0} + b_2) & \cdots & f(w_{\tilde{N}}x_{N_0} + b_{\tilde{N}}) \end{bmatrix}$ (5)

计算输出权重矩阵 $\boldsymbol{\beta}_0 = \boldsymbol{M}_0 \boldsymbol{H}_0^{\mathrm{T}} \boldsymbol{T}_0$ ,其中 $\boldsymbol{M}_0 = (\boldsymbol{H}_0^{\mathrm{T}} \boldsymbol{H}_0)^{-1}, \boldsymbol{T}_0 = [t_1, t_2, \cdots, t_{N_0}]^{\mathrm{T}}$ 。

此时,给定期望残差  $\varepsilon$ ,对于单输出模型若  $E(H_0) = \frac{\|H_0\beta_0 - T_0\|}{N_0} > \varepsilon$ ,则新的隐藏节点被 添加到现有模型,此时隐含层输出矩阵  $H_1 = [H_0, \sigma H_0]$ 。计算此时的残差  $E(H_1)$ ,迭代直到残差小于 期望值。

EM-ELM 的训练时间较 ELM 有所增加,训练时间受到给定期望残差和初始隐含层节点个数的影响,但是依然对 BP 神经网络有着数量级的优势。

## 3.3 EM-ELM 在线序列训练实现

为适应复杂的电气环境,提出根据本地数据进行 OS-EM-ELM 训练,流程如下。

(1)在此前训练的模型的基础上,获得新的本

地样本 
$$C_{k+1} = \{(x_i, t_i)\}_{i=0}^{k+1} \sum_{j=0}^{N_j} n_j$$

- - /

此时新的隐含层输出矩阵变为:

$$\boldsymbol{H}_{k+1} = \begin{bmatrix} f(w_1 x_{(\sum_{i=0}^{k} N_j + 1)} + b_1) & f(w_2 x_{(\sum_{i=0}^{k} N_j + 1)} + b_2) \\ f(w_1 x_{(\sum_{i=0}^{k} N_j + 2)} + b_1) & f(w_2 x_{(\sum_{i=0}^{k} N_j + 2)} + b_2) \\ \vdots & \vdots \\ f(w_1 x_{(\sum_{i=0}^{k+1} N_j)} + b_1) & f(w_2 x_{(\sum_{i=0}^{k+1} N_j)} + b_2) \end{bmatrix}$$

$$\cdots f(w_{\widetilde{N}} x_{(\sum_{i=0}^{k} N_{j}+1)} + b_{\widetilde{N}})$$

$$\cdots f(w_{\widetilde{N}} x_{(\sum_{i=0}^{k} N_{j}+2)} + b_{\widetilde{N}})$$

$$\vdots$$

$$\cdots f(w_{\widetilde{N}} x_{(\sum_{i=0}^{k} N_{j})} + b_{\widetilde{N}})$$

$$(6)$$

(2)重新计算输出权重矩阵:

$$\boldsymbol{\beta}_{k+1} = \boldsymbol{\beta}_{k} + (\boldsymbol{M}_{k} - \boldsymbol{M}_{k}\boldsymbol{H}_{k+1}^{T}(\boldsymbol{I} + \boldsymbol{H}_{k+1}\boldsymbol{M}_{k}\boldsymbol{H}_{k+1}^{T})^{-1}$$
$$\boldsymbol{H}_{k+1}\boldsymbol{M}_{k})\boldsymbol{H}_{k+1}^{T}(\boldsymbol{T}_{k+1} - \boldsymbol{H}_{k+1}\boldsymbol{\beta}_{k})$$
(7)

此时令 k = k + 1,完成一次在线序列迭代,每次训练重复迭代过程。在线训练可以使权重矩阵在 原有基础上更新而不是每一次都重新训练。得益于 ELM 类算法的计算量小的特点,OS-EM-ELM 训练 可以很好适应边缘计算的要求。

# 4 边缘侧电弧故障识别步骤

在电网末端配电箱中对回路的交流电信号进行 高精度的实时采集,对该采样数据在时间序列上进 行完整性检验,通过时基计时器和一个周期的采样 点数来确保周期的完整性和同步性。

根据第2节电弧电流特征提取与分析,采用时 域特征周期均值差、脉宽百分数、频域特征第1、2次 的部分间谐波因数及能量域特征小波高频分量的周 期能量,组成面向边缘侧电弧识别的特征指标,降低 单一特征带来的不稳定性。周期均值差的标准差和 脉宽百分数通过所列公式进行计算。采用按时间抽 取的基2-FFT 算法提取第1、2次的间谐波因数特 征。小波高频分量周期能量特征是在小波变换得到 的高频分量基础之上进行周期能量计算。将提取的 4种特征作为 EM-ELM 模型的输入,模型经过神经 网络运算输出该样本的识别结果标签。当模型判断 该样本为故障样本时,故障特征量累加器 ARC\_ NUM 执行累加操作。

根据 GB 14287.4 相关国家标准,当被探测线路 在 1 s 内发生 14 个及以上半周期的故障电弧时,则 判定为故障电弧。在 1 s 窗口内 ARC\_NUM 超过该 阈值,则认为线路发生了电弧故障,并对故障标志位 ARC\_FAULT 置 1。

— 1218 —

为适应复杂的电气环境,提出在线序列 OS-EM-ELM 训练方法进行权重矩阵迭代,现场获取参数后 需要剔除漏检和误报数据以免污染样本库,总体流 程如图 10 所示。当监测的场景发生变化,整个电路 整体阻抗、感抗发生改变,电流特性与初始训练的样 本相比发生较大偏离,OS-EM-ELM 训练方法能在边 缘侧快速适应并更新权值参数,提高识别准确率。 权值的更新频率通过程序设定,更新频率高对实时 计算的要求高,反之则对装置存储数据的容量要求 高。



图 10 边缘侧电弧故障识别流程图

# 5 实验验证与分析

## 5.1 EM-ELM 算法实验

本文提出基于 EM-ELM 适应边缘侧的电弧识 别算法,为验证该电弧识别方法的有效性,对电弧故 障检测算法初始化训练后进行实验测试。以下极限 学习机的计算结果均是相同初始条件下 10 次独立 运行取平均值。

从第1节建立的数据库中获取不同场景的 2200个样本,其中1100个正常样本、1100个故障样 本。根据第2节的方法,提取所有样本的4个特征。 将这些场景的正常故障各100个样本中随机各抽取 80个样本,作为训练集,剩下的作为测试集;正常样 本标签为1,故障样本标签为2。

在 CPU 为 3.4 GHz 条件下下, EM-ELM 初始节 点设置为 20, 残差期望 0.002。BP 使用隐含节点寻 优, 起始节点数为 3, 迭代限制 20 次。SVM 采用 fitcsvm 函数。对比 EM-ELM、BP、SVM 算法,结果如 表 3 所示。

表 3 EM-ELM、BP、SVM 算法对比

训练方法	训练用时/s	测试精度
EM-ELM	0.1530	0.99
BP	16.080	0.91
SVM	1.470	0.93

在相同情况下,计算量的大小可由训练时间长 短直观地呈现。得益于 ELM 的随机化权值和偏置, 极限学习机的训练速度比传统神经网络(如 BP 算 法)速度快很多。EM-ELM 可以优化节点数目,达到 预期精度。

记录 EM-ELM 每次迭代训练时的残差和训练 集准确率如图 11 所示。从图中可以看出,随着迭代 次数的增加残差和训练准确度变化趋于平缓,之后 迭代的效率就会非常低,且容易陷入过拟合。通过 设定期望残差 0.002 使迭代在 21 次停止,EM-ELM 相比于传统 ELM 通过残差最小化方法在提升准确 率的同时可控制计算的复杂度。综合分析训练用时 与精度,极限学习机算法十分适合在边缘侧应用。



图 11 EM-ELM 残差和训练集准确率于迭代次数的关系

EM-ELM 最终输出的测试集结果如图 12 所示。 各测试样本所对应的实验场景如表 4 所示。从结果 可以看出,EM-ELM 的电弧故障总体识别率比较高, 以 1.5 做为阈值,测试集识别正确率达到了 99.33%。 EM-ELM 判别是总体程序的一部分,依据总体识别 方法的设计,只有 EM-ELM 模型在一段时间内连续 发生多次误判,到达判断阈值之后,该识别方法才会 产生误动作。



图 12 EM-ELM 训练输出

表 4 EM-ELM 训练输出样本来	打照表
--------------------	-----

测试样本编号	对应的实验负载	样本类别
1 ~ 20	由北主	正常运行
$21 \sim 40$	电小亚	电弧故障
$41 \sim 60$	由 却	正常运行
$61 \sim 80$	电机	电弧故障
$81 \sim 100$	由	正常运行
$101 \sim 120$	电叭风(中档证)	电弧故障
$121 \sim 140$	由吃团(	正常运行
141 ~ 160	电叭风(同臼位)	电弧故障
$161 \sim 180$	中北主,中和	正常运行
$181\sim 200$	电小亚中电机	电弧故障
$201\sim 220$	由吃豆(由档信)」由却	正常运行
$221\sim 240$	电外风(千佰位)+电机	电弧故障
$241\sim 260$	由吃豆( ) 」 由 却	正常运行
$261\sim 280$	电外风(间扫应)+电机	电弧故障
$281\sim 300$	咽小哭	正常运行
301 ~ 320	吸主益	电弧故障
321 ~ 340	电水壶+吸尘器	正常运行
341 ~ 360		电弧故障
361 ~ 380	电吹风(中档位)+吸尘器	正常运行
$381 \sim 400$		电弧故障
$401 \sim 420$	电吹风(高档位)+吸尘器	正常运行
421 ~440		电弧故障

#### 5.2 在线序列 EM-ELM 实验

分析第 341~360 号电水壶+吸尘器故障样本, 该样本故障时电流波形平肩部狭窄且偏离零点较远,其4个特征值偏离其他样本较远,由此出现了识 别不稳定。本文提出的 OS-EM-ELM 训练方法能应 对这种情况。根据表5 样本设计实验,样本均来自 第1节建立的数据库,各样本集之间没有交集。

表5 在线序列 EM-ELM 实验样本

样本集编号	负载	数量描述
样本集1	电水壶	100 正常 + 100 故障
样本集2	电水壶 + 吸尘器	30 正常 + 30 故障
样本集3	电水壶 + 吸尘器	30 正常 + 30 故障
样本集4	电水壶 + 吸尘器	30 正常 + 30 故障

(1)首先使用样本集1训练EM-ELM模型,使用样本集2为测试集,记录识别结果编号为0~60。

(2)运用第4节提出的 OS-EM-ELM 训练方法, 将样本集2作为新增样本加入总训练集,以样本集 3 为测试集,记录识别结果编号为61~120。

(3)将样本集3作为新增样本加入总训练集,以样本集4为测试集,记录识别结果编号为121~180。

将在线序列实验结果汇总获得图 13。从结果 可以看出,经过在线训练,以1.5为阈值,识别错误 的样本从4个降为0个,识别精度提升明显,输出的 稳定性增加。可见引入在边缘侧的在线序列训练对 识别率的提高有重要作用。





## 5.3 边缘侧电弧识别方法泛化性能实验

结合 GB 14287.4 相关国家标准进行测试。采 用应急管理部沈阳消防研究所研发的 AFD100 电弧 模拟检测系统,如图 14 所示,系统包含算法未知的 新样本,以验证边缘侧电弧识别算法的泛化性能。

(1) 电弧故障实验

分别对不同的负载类型进行电弧故障实验,实 验次数和识别率如表6所示。

(2) 误报警实验

误报警是验证电弧故障检测装置在复杂电气条 件干扰下是否会发生报警。实验要求和结果如表 7



图 14 AFD100 电弧模拟检测系统

表6 不同负载类型电弧故障实验结果

负载	总次数/次	漏检次数/次	识别率/%
多盏日光灯	50	1	98
多个开关电源	50	2	96
负载箱	50	0	100
负载抑制实验	50	2	96
线路阻抗抑制实验	50	2	96

表7 误报警试验负载的相关要求及实验结果

负载	实验方法	实验时间/s	误报警率/%
电磁炉	1800 W 档位下启动 并运行	10	0
微波炉	启动并运行	10	0
电熨斗	通过调节温度控制 旋钮,使控温触点 接通和分断10次	60	1
电子变速 手电转	手电钻在空载状态下 转速从最低到最高, 再从最高到最低 往复2次	10	2
变频空调	启动并运行	60	1

电弧故障的实验结果表明,电弧故障识别方法 的识别率可以达到96%以上,误报警实验结果小于 2%。

# 6 结论

电弧故障的高度随机性、复杂性使得其难以被 准确识别。针对当前复杂电弧识别算法计算量大、 对硬件算力要求高、但电弧故障检测装置分布在电 网的末端又需要有一定的自主判断和适应能力这一 需求,提出了基于 OS-EM-ELM 的边缘侧电弧识别 方法。使用周期均值差、脉宽百分数、第1和2次部 分间谐波因数及小波高频分量能量作为电弧故障识 别输入特征,为交流串联电弧故障识别提供可靠的 数据支持。

理论分析和实验结果表明,本文所提出的边缘 侧电弧故障检测方法,结合了 EM-ELM 和在线序列 学习,具有计算量小、识别准确度高、适应性强以及 应用成本低的特点,可为电弧检测研究及边缘侧电 弧故障保护器的研制提供一种可靠方法和思路。

## 参考文献

- [1] 冉文博. 高层建筑火灾特点及预防措施[J]. 建筑工 程技术与设计, 2017(12):3162-3162.
- [2] 王尧,田明,牛峰.低压交流电弧故障检测方法研究 综述[J].电器与能效管理技术,2018(10):8-13,44.
- [ 3] CASSIE A M. A new theory of rupture and circuit severity [J]. CIGRE Report, 1939,102:588-608.
- [ 4] MAYR O. Contributions to the theory of the static and dynamic arcs[J]. Elektrotech, 1943,37(12):588-608.
- [5] SCHAVEMAKER P H, VAN D S L. An improved Mayrtype arc model based on current-zero measurements [J].
   IEEE Transaction on Power Delivery, 2000,15(2):580-584.
- [6] HABEDANK U. Application of a new arc model for the evaluation of short-circuit breaking tests [J]. IEEE Transactions on Power Delivery, 1993,8(4):1921-1925.
- [7] 李玮祯, 曲娜, 张帅. 基于小波分析和 Schwarz 模型的 串联电弧故障仿真研究[J]. 消防科学与技术, 2020, 39(9):1260-1263.
- [8] STOKES A D, OPPENLANDER W T. Electric arcs in open air [J]. Journal of Physics D Applied Physics, 1991,24(1): 26.
- [9] 刘艳丽, 郭凤仪, 李磊. 一种串联型故障电弧数学模型[J]. 电工技术学报, 2019,34(14):2901-2912.
- [10] 徐秦乐,张金艺,徐德政.高精度故障电弧检测多传 感器数据融合算法[J].上海大学学报(自然科学 版),2014,20(2):165-173.
- [11] 丁鑫, 竺红卫, 殷浩楠. 基于快速傅里叶变换(FFT)
   的交流电器电弧快速检测法[J]. 电器与能效管理技术, 2015(21):8-12.

- [12] 蔡杰轩. 基于 5 次谐波分量概率分布的故障电弧识别 方法的研究[D]. 沈阳: 沈阳工业大学, 2017.
- [13] 缪希仁,郭银婷,唐金城.负载端电弧故障电压检测
   与形态小波辨识[J].电工技术学报,2014,29(3):
   237-244.
- [14] 佟为明, 佟春天, 金显吉. 基于 STM32 的故障电弧检测装置设计[J]. 强激光与粒子束, 2019,31(3):45-51.
- [15] HAN C, WANG Z, TANG A. Recognition method of AC

series arc fault characteristics under complicated harmonic conditions [J]. IEEE Transactions on Instrumentation and Measurement, 2021,70:1-9.

- [16] 苏晶晶, 许志红. 基于混沌分形理论的故障电弧诊断 方法研究[J]. 电机与控制学报, 2021,25(3):125-133.
- [17] 张丽萍, 缪希仁, 石敦义. 基于 EMD 和 ELM 的低压 电弧故障识别方法的研究[J]. 电机与控制学报, 2016,20(9):54-60.

# Edge-side series arc fault detection method based on OS-EM-ELM algorithm

XUE Peng, PAN Guobing, OUYANG Jing, CHEN Xingxing

(College of Mechanical Engineering, Zhejiang University of Technology, Hangzhou 310023)

#### Abstract

The high randomness and complexity of arc fault make it difficult to be accurately identified. Aiming at the problem that the traditional arc recognition algorithm has low real-time performance and high hardware computing power, an error minimization extreme learning machine (EM-ELM) arc fault detection method suitable for edge computing, multi-load types and multi-feature combination is proposed. Through fast Fourier transform (FFT) and db4 wavelet decomposition, the period mean difference, pulse width percentage, inter-harmonic factor and wavelet high-frequency energy are extracted as the input characteristics of the arc fault detection algorithm on the edge side. On this basis, OS-EM-ELM combined with online sequence (OS) method is proposed, and the algorithm is improved by using field operation data to improve adaptability. The experimental results show that the proposed edge side arc fault detection method can effectively distinguish the normal and arc fault waveform, and it is suitable for the complex situation of working with a variety of loads at the same time. The calculation amount is small, the real-time performance is high, the adaptability is strong, and the application cost is low, which is more in line with the requirements of edge calculation of arc detection device.

Key words: alternating current (AC) series arc, edge side, fast Fourier transform (FFT), fault identification, extreme learning machine (ELM)