

基于模态分解与特征匹配的串联故障 电弧识别方法研究

陈浩¹, 阎俏^{1,2}, 张桂青^{1,2}, 曹建荣¹, 张汉元^{1,2},
庄园¹, 任飞¹, 田丰¹

(1. 山东建筑大学 信息与电气工程学院, 济南 250101

2. 山东省智能建筑技术重点实验室, 济南 250101)

摘要: 串联故障电弧具有隐蔽性强、短时释放热量大等特点, 过流型断路器难以及时发现或采取动作, 极易引发电气火灾, 造成重大损失和人员伤亡, 因此实现建筑内串联故障电弧的快速可靠识别与监测具有重大意义; 按照线路负载类型对电气线路高频电气参数运行数据进行分析, 利用结合串联电弧故障特征的互补集合经验模态分解 (CEEMD, complementary ensemble empirical mode decomposition) 方法, 实现对电气线路串联电弧故障的识别; 经实验验证, 并与灰度梯度共生矩阵与支持向量机 (GLGCO-SVM)、时域可视卷积神经网络 (TDV-CNN) 等方法识别结果进行对比效果更好, 识别准确率达到 94.8% 及以上。

关键词: 电气火灾; 串联故障电弧; 互补集合经验模态分解; 电气参数; 故障识别;

Research on Identification Method of Series Arc Faults Based on Modal Decomposition and Feature Matching

CHEN Hao¹, YAN Qiao^{1,2}, ZHANG Guiqing^{1,2}, CAO Jianrong¹,
ZHANG Hanyuan^{1,2}, ZHUANG Yuan¹, REN Fei¹, TIAN Feng¹

(1. School of Information and Electrical Engineering, Shandong Jianzhu University, Jinan 250101, China;

2. Shandong Key Laboratory of Intelligent Buildings Technology, Jinan 250101, China)

Abstract: Series fault arc has the characteristics of strong concealment and large heat release in short time. It is difficult for over current circuit breakers to detect and take action in time, which is easy to cause electrical fire and cause significant losses and casualties. Therefore, it is of great significance to realize the rapid and reliable identification and monitoring of series fault arc in buildings. According to the line load type, the operation data of high frequency electrical parameters of electrical lines are analyzed, and the CEEMD combined with the characteristics of series arc fault is used to realize the identification of series arc fault of electrical lines. Compared with the recognition results of GLGCO-SVM and TDV-CNN, the recognition accuracy reaches 94.8 % and above.

Keywords: electrical fire; series fault arc; complementary ensemble empirical mode decomposition; electrical parameters; fault identification

0 引言

国家消防救援局发布的 2020 年火灾出警数据显示, 电气火灾数量多年来依旧持续庞大, 占各种火灾数量的 1/3 以上, 大型火灾中有一半以上系电气原因引发。常见的电气火灾主要由过载、过流、电弧、漏电等原因引起^[1], 相比其他火灾诱因, 串联故障电弧隐蔽性强, 不会引起断路器

或熔断器动作, 因此, 高效可靠的实现对串联故障电弧进行识别和监测至关重要。

近些年, 学者们采用多种方法致力于串联电弧故障的识别。文献 [2] 以正交二次样条小波为工具, 通过检测电流周期性奇异点间接检测串联电弧故障; 文献 [3] 基于小波变换和支持向量机, 提取特征进行分类; 文献 [4] 利用 SWT 算法提取波形动态特征, 输入 SVM 进行决策判断;

收稿日期:2021-08-19; 修回日期:2021-09-22。

基金项目:山东省重点研发计划项目(2019JZZY010115)。

作者简介:陈浩(1997-),男,山东日照人,硕士研究生,主要从事建筑设备智能化与电弧故障检测方向的研究。

张桂青(1962-),男,山东济南人,博士,二级教授,博导,主要从事建筑设备智能化、故障诊断、物联网与智慧建筑等方向的研究。

曹建荣(1965-),男,山东济南人,博士,教授,主要从事模式识别与智能信息处理方向的研究。

通讯作者:阎俏(1976-),女,山东烟台人,博士,副教授,主要从事电力故障分析、智慧建筑、物联网方向的研究。

引用格式:陈浩,阎俏,张桂青,等. 基于模态分解与特征匹配的串联故障电弧识别方法研究[J]. 计算机测量与控制, 2021, 29(11): 53-60.

文献 [5] 利用马尔拉特算法, 将时频信号分解为高低频两部分, 将高频系数均值及其方差作为判据。以上论文在一定程度上都实现了对串联故障电弧的识别, 但漏报误报率较高, 识别精确度有待提高。

互补集合经验模态分解 (CEEMD) 方法可以使复杂信号自适应的分解为多个本征模态函数 (IMF, intrinsic mode function) 与余差的组合, 其 IMF 分量包含了原信号的不同时间尺度的局部特征, 基函数是由数据本身所分解得到, 对非平稳、非线性数据的处理优势明显, 同时又解决了经验模态分解方法 (EMD, empirical mode decomposition) 的端点效应和模态混叠问题, 因此近年来在不同工程领域得到了众多应用。赵雪花等将 CEEMD 与广义回归神经网络组合对汾河上游月径流量进行了分析^[6], 深入挖掘了时间序列信号的模态分量特征, 比较准确地获得了月径流预测值, 应用于有限水资源的分配领域; 秦庆山将模态分解方法应用于配电网单相接地故障选线^[7], 将各线路首端零序电流分解后获取最高频分量, 解决了电力系统单相接地故障选线问题; 韩博跃等提出了一种基于改进 IWT-CEEMD-cICA 的故障诊断方法^[8], 通过峭度值配合选取有效函数, 与其他方法的配合, 提取目标振动信号, 应用于滚动轴承故障识别性。

为实现建筑内串联故障电弧的快速可靠识别与监测, 本文对电气线路高频电气参数进行分析, 采用基于模态分解与特征匹配的识别方法, 在识别结果和识别速度上较常规方法均有所提高, 同时分步式的识别方法适用于云边协同式的串联电弧监测系统的实际部署。

1 基于模态分解与特征匹配的串联故障电弧识别算法

1.1 算法整体框架

串联故障电弧是在电场作用下击穿空气介质激烈放电的燃烧过程, 同时伴随大量热量的释放。当配电线路上出现长期载流量超限、线路疏于检修、绝缘老化、接线端子连接不良等情况时, 极有可能出现持续性电弧^[9], 串联电弧型电气火灾可等效为在原有线路中串联一个不规则动态变化的电弧电阻, 一般不会使原线路上的电流发生激烈变化, 线路上的断路器、熔断器等传统保护设备无法有效发挥作用^[10]。长时间的小弧燃烧也会使局部接触电阻增大, 埋下电气火灾隐患。经模拟实验探究, 串联电弧故障高频周期电流受线路负载的影响极大, 使得识别的难度增大, 对监测方法和识别算法提出了较高要求。本文将电气参数监测器采集到的高频周期电流差值信号进行预处理后, 输入识别算法, 算法主要分为以下 4 个部分。

1) 数据预处理。根据电弧电流特征, 对采集的数据进行巴氏滤波^[11], 后进行归一化处理, 能够有效排除高频干扰信号对电弧识别的干扰, 避免滤波过程中特征量损失, 同时避免因采集数据值过大而对细小电弧识别产生影响, 提高识别的准确度^[12]。

2) 一阶特征提取。一阶提取为粗提取, 以相对宽泛的

阈值将可能的串联故障电弧纳入二阶提取范围, 同时确定负载类型。

高频电气参数监测器实时采集被测线路上的电气参数, 基于事件触发机制实现数据的上报处理, 一阶提取识别机制阈值 1 为电流有效值变化量, 阈值 2 为电流谐波中各次谐波占比。阈值 1 触发后, 将上报 3 个周波中的第 1 周波数据按识别特征通过高斯函数进行数据拟合, 拟合产生 3 种输出结果: 阻性、阻感、非线性, 确定负载类型。阈值 1 和阈值 2 均通过后进行二阶特征提取识别。

3) 二阶特征提取。一阶特征识别通过后, 持续捕捉上报此后连续多个周波电气参数, 进行二阶特征提取识别。二阶特征提取识别即对一阶提取后的疑似异常数据的周期电流差值信号进行 CEEMD 分解, 获取 IMF 实际值, IMF 作为二阶特征用于算法下一步的特征匹配。

4) 特征匹配。利用实验获取的正常数据与故障数据, 构建差值信号送入 CEEMD 算法, 获取 IMF 理论值作为匹配模板, 与步骤 3) 中 IMF 实际值进行特征匹配运算^[15]。特征匹配选用相似距离函数动态时间规整算法 (DTW, dynamic time warping), DTW 基于动态规划的思想, 以两时间序列相似度作为输出结果, 在本算法中代表了电弧识别的结果, 即当 DTW 运算结果符合相似度判定条件时, 认定当前线路存在串联故障电弧。

实际监测中, 一阶特征识别提取通过后, 持续向云平台服务器上报数据, 进行二阶特征识别提取, 直至一阶特征提取不满足, 停止上报。即一阶特征的提取识别在本地高频电气参数采集器中实现, 二阶特征的提取识别是在远端服务器实现。由于串联电弧故障持续时间存在较强随机性, 获取的串联电弧故障 3 周波包含的电弧信息长度同样具有随机性, 所以在 CEEMD 分解的基础上应用 DTW 方法, 可以有效利用其动态延展特点, 解决串联故障电弧随机出现在上半周波或下半周波对识别结果的影响, 同时解决两不同长度时间序列信号相似性的求解问题。识别算法整体框架流程图如图 1 所示。

1.2 模态分解与特征匹配方法

串联故障电弧可以等效为原有电气设备与故障电弧特征的叠加, 如果将串联电弧故障发生时的周期电流和正常工作电流分别进行分解, 提取串联电弧故障特征, 就能以此为依据, 训练电气火灾监测算法。在正常和故障两个维度下分别输入识别算法, 构建故障向量模型, 实际应用时, 通过合理设置时间窗格, 将窗格前后数据差向量输入检测算法, 通过特征匹配方法实现串联电弧故障识别。

常用的模态分解方法有傅里叶变换、小波变换以及希尔伯特-黄变换等^[17]。傅里叶变换产生的分解结果会忽视原有时间序列中的先后顺序, 且其窗函数和时间窗尺度的选取会对分解结果产生较大影响。小波分解的基函数和分解层数对最终结果的影响较大, 其选取具有很大的盲目性。希尔伯特-黄变换中 EMD 分解是一种自适应分解, 分解产生的每一个模态分量都代表了一种特殊振荡模式, 其分解

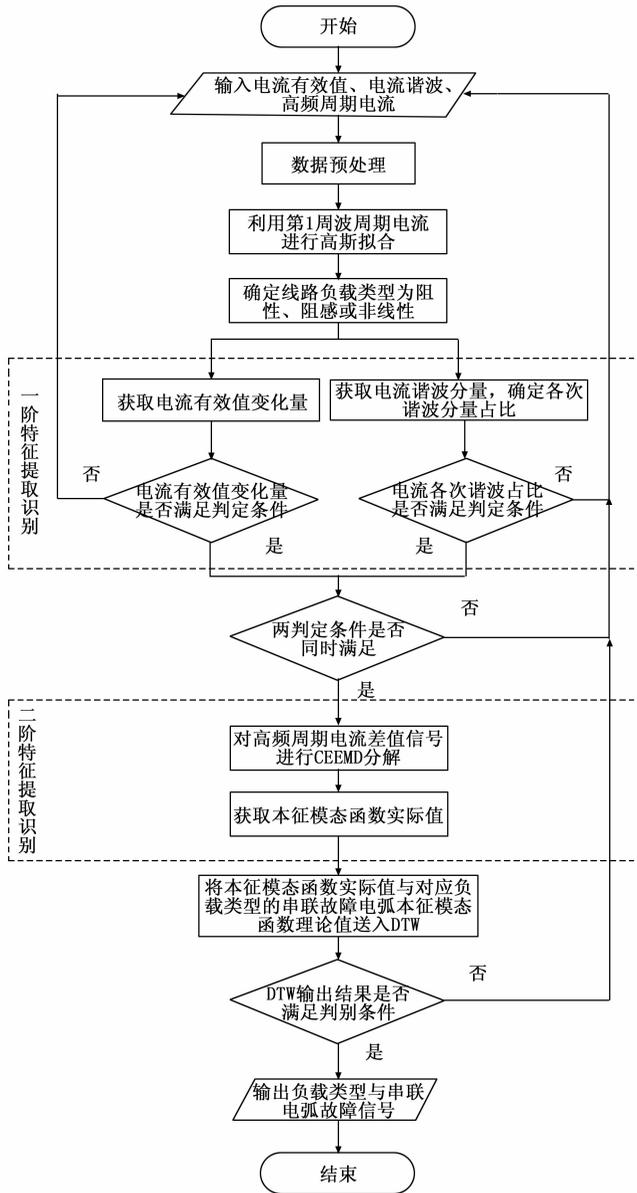


图 1 算法整体框架流程图

层数由信号细节特征决定^[14], 不需要人为选定基函数或给出过多参数设置, 但经常存在端点效应和模态混叠现象。CEEMD 分解则是对 EMD 分解的优化和改进, 通过引入一定条件的白噪声, 通过多次集成平均的形式, 使剩余噪声维持在一定范围内, 同时通过端点延拓的方法, 解决端点处 EMD 单向分解结果不理想和一种振荡模式下混有一种以上振荡信号的问题。

本文对 CEEMD 的完全自适应分解做了限制, 加入迭代判断后, 自适应分解层数可控, 将分解目标由最优解改变为快速确定解, 取消余差判断与运算输出, 将最后一层余差合并入分解结果, 减少分解步骤, 提高分解速度, 同时改变了自适应分解的对象, 对触发机制前后的向量差进行分析, 不依赖对原有信号或当前信号进行分析, 使算法数据处理量更小, 更适应快速反应的串联电弧故障识别。

对周期电流 CEEMD 分解的流程图如图 2 所示^[6]。

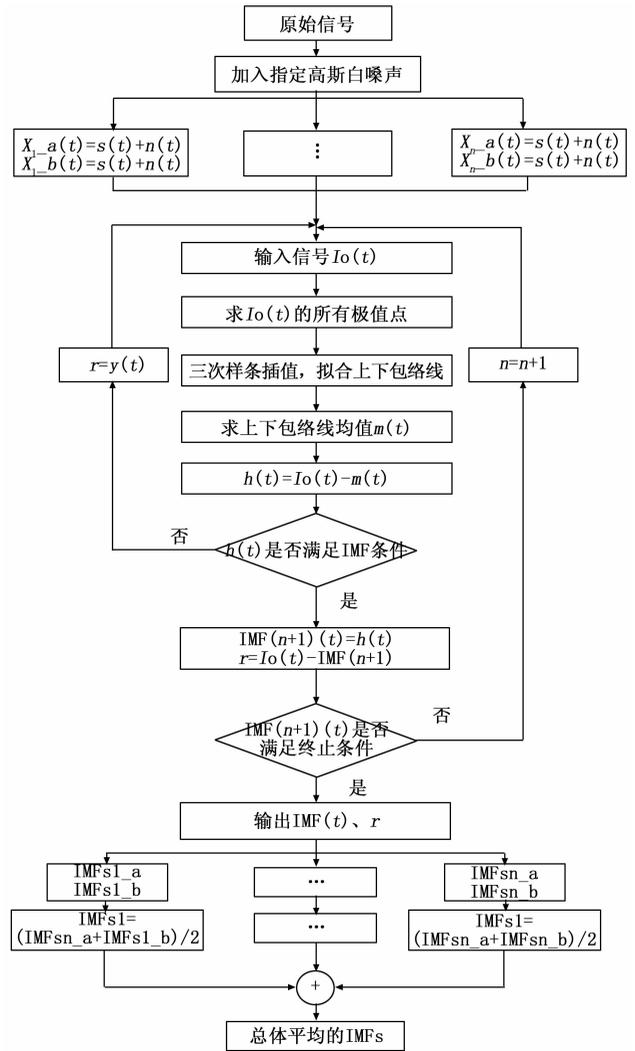


图 2 周期电流 CEEMD 分解流程图

其中, IMF_1 的计算方法为:

$$IMF_1 = \frac{1}{T} \sum_{i=1}^T E_1 [I(t) + \epsilon_0 \omega^i(t)] \quad (4)$$

$R_1(t)$ 的计算方法为:

$$R_1(t) = I(t) - IMF_1 \quad (5)$$

IMF_2 的计算方法为:

$$IMF_2 = \frac{1}{T} \sum_{i=1}^T E_1 [R_1(t) + \epsilon_1 E_1 \omega^i(t)] \quad (6)$$

$R_k(t)$ 的计算方法为:

$$R_k(t) = R_{k-1}(t) - IMF_k \quad (7)$$

IMF_{k+1} 的计算方法为:

$$IMF_{k+1} = \frac{1}{T} \sum_{i=1}^T E_1 [R_k(t) + \epsilon_k E_k \omega^i(t)] \quad (8)$$

E_k 即为算子期望, $\omega^i(t)$ 为均值是零的典型高斯白噪声信号, ϵ_k 为系数允许在每个阶段选择信噪比, $I(t)$ 为原高频周期电流序列。

动态时间规整 (DTW) 起初多被用于语音识别领域,

DTW 最显著的优势就是不受时间序列长度、频率等条件的约束,通过动态匹配最优路径,以距离作为衡量标准表征任意两个时序信号的相似性。本文以 IMF 理论值与 IMF 实际值分别为横纵坐标,构建 $n \times m$ 维矩阵网格,目的是为了把两个时间序列进行延伸和缩短,产生部分理论对应点,使两时间序列点对点,通过依次计算数据点与理论对应点之间的距离,来寻找两时间序列累加距离的最小值。

本文将 IMF 理论值作为 S_1 :

$$S_1 = [x_1, x_2, x_3, \dots, x_m] \quad (9)$$

将 IMF 实际值作为 S_2 :

$$S_2 = [y_1, y_2, y_3, \dots, y_n] \quad (10)$$

以上述两时间序列对应元素组成距离代价矩阵 D :

$$D(x_m, y_n) = \begin{bmatrix} d(x_1, y_1) & \dots & d(x_1, y_n) \\ \vdots & \ddots & \vdots \\ d(x_m, y_1) & \dots & d(x_m, y_n) \end{bmatrix} \quad (11)$$

其中: $d(x_m, y_n)$ 为此两序列的欧氏距离:

$$d(x_m, y_n) = \sqrt{(x_m - y_n)^2} \quad (12)$$

两时间序列的最优路径 $\xi(S_1, S_2)$:

$$\xi(S_1, S_2) = D(x_m, y_n) + \min[\xi(x_{i-1}, x_n), \xi(x_m, y_{j-1}), \xi(x_m, y_n)] \quad (13)$$

其中:

$$\xi(1, n) = \sum_{i=1}^n d(x_1, y_i) \quad (14)$$

$$\xi(n, 1) = \sum_{i=1}^n d(x_i, y_1) \quad (15)$$

两时间序列“相似度”越高, $\xi(S_1, S_2)$ 的数值越接近零,反之越大。

2 实验验证

2.1 总体方案

根据《电气火灾监控系统第 4 部分:故障电弧探测器》GB14287.4 搭建交流串联电弧故障实验台^[7]。实验台由模拟电弧发生器、实验电路和电气参数监测器组成,如图 3 所示。模拟电弧发生器由铜电极与石墨电极组成,两电极间隔可通过轨道螺旋调节,最小可使两电极紧密接触,保持稳定连接,最大可使电路完全断开,处于绝对断路状态。

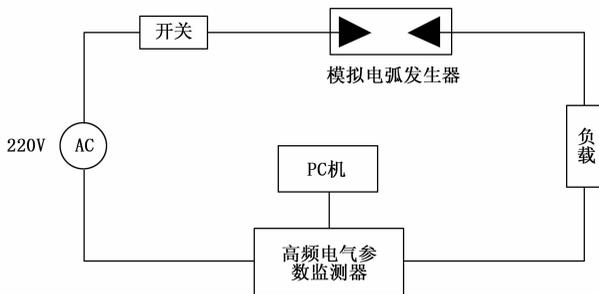


图 3 串联电弧模拟实验台及实验台电路

2.2 数据采集与分析

采集正常运行数据时,将模拟电弧发生器两电极紧密

接触,使之处于完全通路状态,电气参数监测器实时监测线路上的电气参数,断开电路,更换负载,重复实验操作。

采集串联电弧数据时,将模拟电弧发生器两电极分开,保持较小空气间隙,电气参数监测器实时监测线路上的电气参数,接通电路,可在两电极间观察到明显的电弧声光现象,断开电路,更换负载,重复实验操作。

考虑到实际建筑中电路性质以线性(阻性)和非线性(阻感性、阻感容性)状态出现,数据采集过程中选用额定功率为 800 W 的电热取暖器作为典型阻性负载、额定功率为 220 W 的风机作为典型阻感性负载,额定功率为 60 W 的 LED 白光灯(含芯片控制电路)作为非线性负载,分别模拟了正常工作和串联电弧故障状态下的运行状况^[19],图 4 为经巴氏滤波处理后的高频周期电流波形。

1) 阻性负载:正常工作状态下,由于阻性负载的线性特性,其高频周期电流波形呈现 220 V 交流电源的标准正弦波。发生串联电弧故障时,在正弦波近零点处当两电极间电压不足以击穿中间空气介质时,实验电路呈现短路断路状态,高频周期电流瞬间变零,随着电压的正弦变化,当两电极间电压达到临界起弧值时(临界起弧值与负载类型、电路构造、环境等因素相关),空气介质再次被击穿,实验电路恢复通路状态,高频周期电流值按正弦波波动,在电弧发生时间段内周期性重复出现^[21]。

2) 阻感负载:正常工作状态下,由于受电感器件性能的影响,其电流相位滞后于电压,伴随有一定的畸变,由于不同电路的电阻和电感值比例存在差异,其阻抗角略有不同,所以其波形变化与阻感负载的具体数值有关,但波形趋势一致。发生串联电弧故障时,阻感负载呈现出与阻性负载类似的电流平肩部特征,其发生原因一致,此处不再赘述,但由于正常工作状态时存在的畸变现象,发生串联电弧时的畸变仍然存在。

3) 非线性负载:正常工作状态下,由于内部电子器件阻性、感性、容性的复杂组合,整体电路对外表现出典型的非线性特征,周期性明显。发生串联电弧故障时,由于电容的充放电效应,在平肩部阶段的首和尾会出现较为明显的反向放电过程,周期电流波形图中表现为反向尖峰电流。

2.3 算法验证

一阶提取为双阈值判定,由于一般建筑常规用电器功率为几十到几百瓦不等,正常工作电流有效值一般在 0.2 A 以上,故阈值 1 取为 0.15 A,经先期实验分析对比,阈值 2 谐波占比数值由模拟实验得出。

n 次谐波占比计算方法:

$$P_n = \frac{N_n}{\sum_{i=2}^{13} N_i} \quad (1)$$

其中, P_n 为 n 次谐波占比, N_n 为 n 次谐波数值, $\sum_{i=2}^{13} N_i$ 为除基波外 2~13 次谐波数值的总和(①排除基波:基波数值较高,影响高次谐波占比;②13 次以上谐波基本以 0 形式存在,与整体识别关联性不大)。

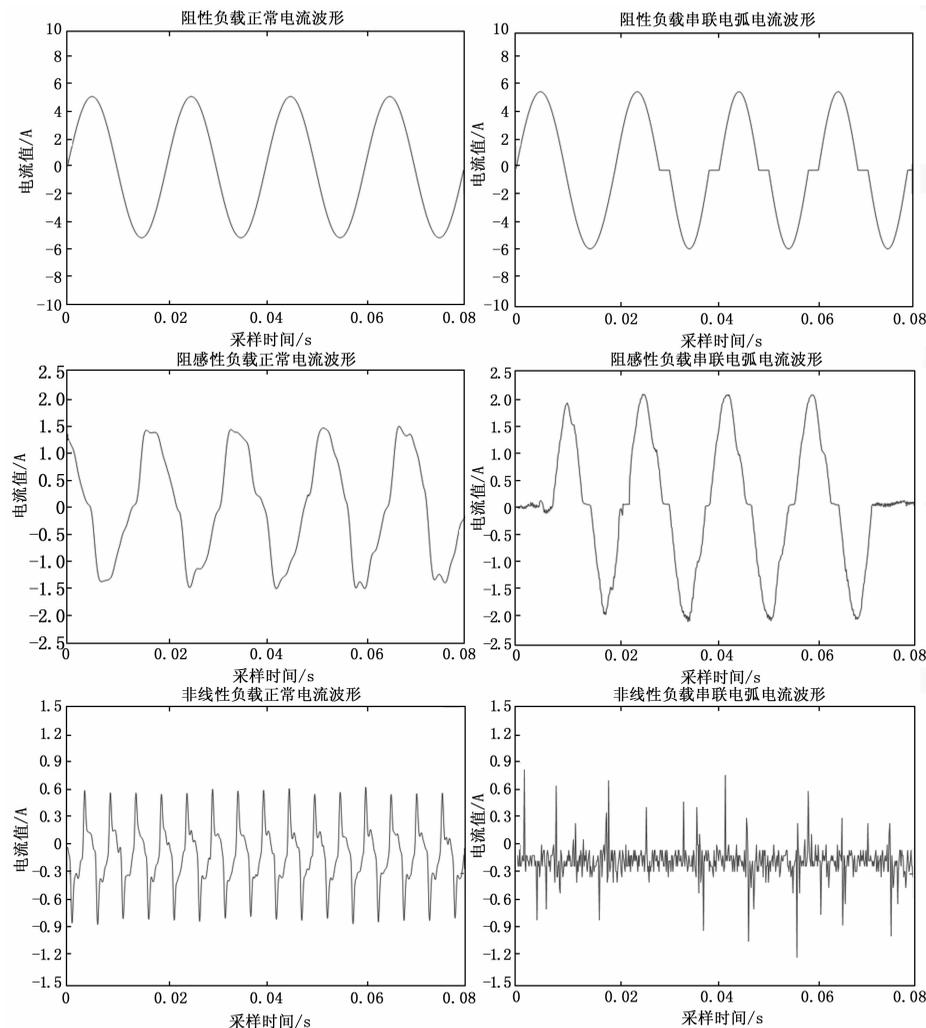


图 4 高频周期电流波形图

综上, 本实验中阈值 1 为预处理后电流有效值变化量 ≥ 0.15 A, 阈值 2 为电流谐波中各次谐波占比, 详见表 1。阈值 1 和阈值 2 均通过后进行二阶特征提取识别。

表 1 一阶特征提取谐波占比阈值表

负载类型	3 次谐波占比	5 次谐波占比	7 次谐波占比	9 次谐波占比
阻性	$\geq 21\%$	$\geq 15\%$	$\geq 12\%$	$\geq 5\%$
阻感	$\geq 13\%$	$\geq 10\%$	$\geq 8\%$	$\geq 5\%$
非线性	$\geq 7\%$	$\geq 8\%$	$\geq 8\%$	$\geq 5\%$

注: 考虑到线路实际运行情况的复杂性, 同时鉴于此阈值仅为二阶提取的一部分, 故阈值 2 判定条件设置宽容参数为 0.75 的容错机制, 即 3~9 次谐波的四重判定条件满足三重即为判定通过。谐波占比由模拟实验得出。

二阶提取是对一阶提取通过后的低频周期电流数据进行 CEEMD 分解, 获取 IMF 实际值, 将其与 IMF 理论值一并送入 DTW 进行运算, 通过合理设置 DTW 结果的判定条件实现特征识别。表 2 为二阶特征提取判别条件表。

表 2 电弧识别结果相似度判别条件

负载类型	判别条件
阻性负载	$(DTW \text{ 输出结果}/10000) \leq 1\%$
阻感负载	$(DTW \text{ 输出结果}/10000) \leq 6\%$
非线性负载	$(DTW \text{ 输出结果}/10000) \leq 8\%$

本文 1.1 节中介绍了本文采用的事件触发机制, 3 个周波共上报 256 点数据。为方便计算, IMF 理论值与 IMF 实际值组成的 DTW 计算矩阵以 100 为矩阵分度值。

1) 阻性负载: 由于阻性电路的线性关系, 根据图 4 可知, 其上报的 3 周波数据具有高度的对称性, 所示实际参与特征匹配的数据点仅为 3 周波中任一周期波的 1/2 半波, 根据 1.2 节 DTW 输出结果的计算办法, 完全匹配下的最优路径即方阵对角线路径, 按照 1.2 节计算办法约为 9 051, 按照表 2 转换为百分制为 0.905 1%, 为保证一定的容错机制调整为 1%。

2) 阻感负载: 由于阻感电路的滞后特性, 根据图 4 可知, 其上报的 3 周波数据均实际参与特征匹配, 按照上述阻性负载的计算办法约为 5.430 5%, 为保证一定的容错机制调整为 6%。

3) 非线性负载: 由于非线性电路的特性, 按照上述阻感负载的计算办法约为 5.430 5%, 因为电弧燃烧段

的首尾均随机发生反向尖峰电流, 即在特征匹配过程中, 最优路径的极限不会是个个方阵对角线的叠加, 经实验测定, 取其最优路径为方阵对角线叠加的 1.3~1.4 倍, 即 7.059 65%~7.602 7%, 为保证一定的容错机制调整为 8%。

但需要特别说明, 表 2 中判别条件数值为本实验条件下兼顾准确率和漏报率的参考值, 同时为便于描述, 将输出结果转换为百分数表示, 实际应用时应在此基础上综合考量线路负载复杂程度做出调整。如: 实际线路虽为阻感负载, 但电感值较小, 此时判别条件应取 [1%, 6%]。

1) 模态分解:

分别将三种负载情况下的正常、电弧差值数据进行模态分解, 分解如图 5~7 所示。上述分解中, 高斯白噪声个数 p 取值为 4, 自上而下首行是高频周期电流信号, 2~5 行波形对应本征模态函数 IMF1~4。

2) 特征匹配:

为验证本文方法的有效性, 在 2.3 的基础上, 将 IMF 理论值与 IMF 实际值共同送入 DTW 运算, 计算后对输出结果进行了数值统计, 散点分布图如图 8 所示。

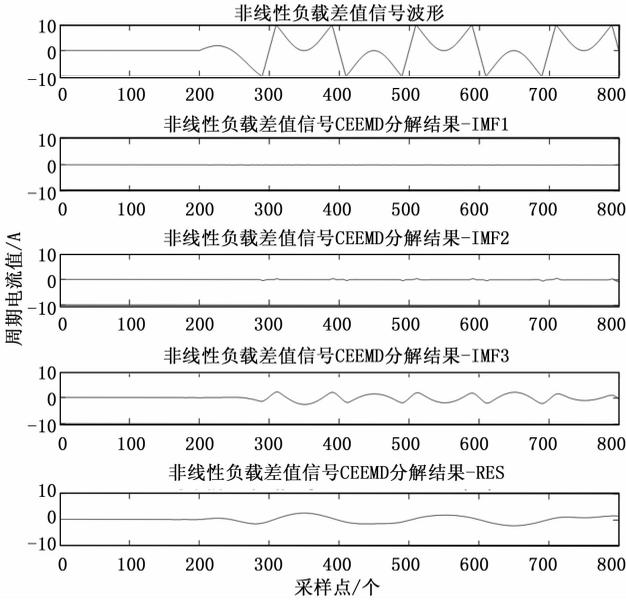


图 5 阻性负载高频周期电流分解图

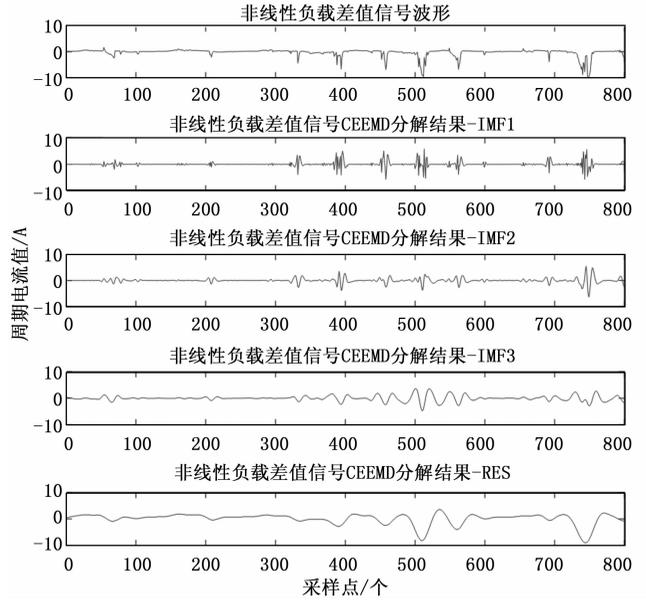


图 7 非线性负载高频周期电流分解图

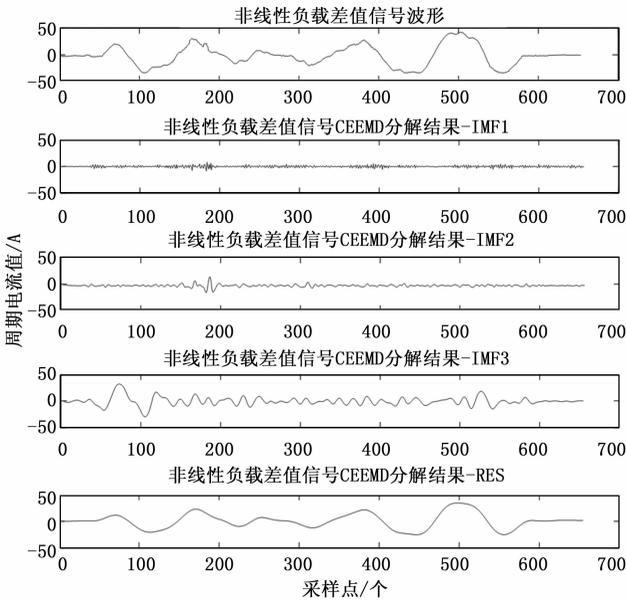


图 6 阻感负载高频周期电流分解图

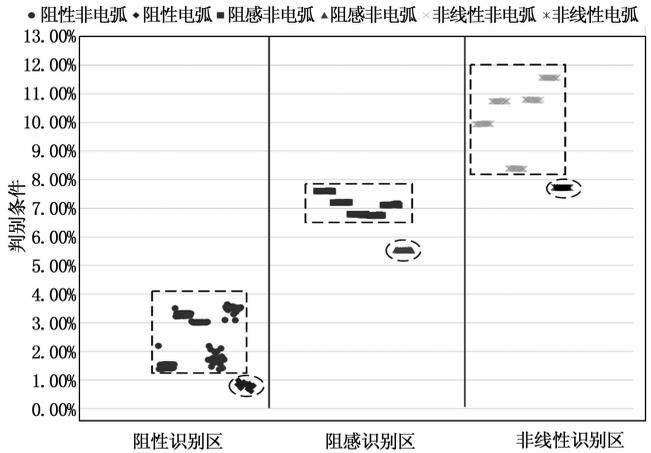


图 8 DTW 结果散点分布图

2.4 结果分析

2.3 节中，我们按照本文方法对 3 类典型负载正常工作与串联故障电弧分别进行一阶、二阶特征提取识别，并给出了此过程的关键分解图与最终识别结果的散点分布图。

通过最终的识别结果散点分布图可以发现，在某一类负载识别区内，本文方法的 DTW 输出结果具有明显的分层现象，上部矩形识别框和下层圆形识别框分别为非电弧状态与电弧状态，未出现明显混叠现象。

1) 纵向对比：

每一类负载识别区内，识别结果中以表 2 中设定的阈值为界，均出现两层分层现象。阻性非电弧、阻感非电弧、非线性非电弧（3 类正常负载）DTW 判别条件聚堆识别结

果最小值均分别大于 1%、6%、8%，阻性电弧、阻感电弧、非线性电弧（3 类故障负载）DTW 输出值聚堆识别结果最大值均分别小于 1%、6%、8%。

2) 横向对比：

每一类负载识别区内，串联故障电弧 DTW 判别条件分层聚堆最靠下，即识别结果值最小，根据 DTW 的计算原理，即相似度最高。非电弧数据由于运行状态的不同，呈现各自分散聚堆现象，但均未发生串联电弧故障，DTW 输出结果均大于电弧数据。因此本文使用的方法及设置的阈值对串联故障电弧的识别真实有效。

本文方法阈值分级设置且具有容错机制，一定程度上限制了散点的分散程度，但仍有部分散点具有离散趋势，主要与放弧强度有关，模拟电弧的释放过程伴随着众多外界因素的干扰，中途可能出现短暂的熄弧与复燃过程，此部分散点是影响识别结果准确率的主要因素。

2.5 与其他识别方法的比较

为验证提出方法对串联电弧故障识别的有效性, 本文选取了 GLGCO-SVM^[22] 与 TDV-CNN^[23] 进行了对比分析, 两篇文献中使用的典型负载类型均与本文相似。GLGCO-SVM 的卷积神经网络相对复杂, 尤其是在特征提取方面, 它以稀疏编码的方式获取关键信息增加了算法的复杂度, 运行时间延长; TDV-CNN 是基于灰度图像处理的方法, 当发生串联电弧故障时线路上会产生大量高频信号, 对信号进行合理滤波后, 只保留电弧特征信号, 但其滤波仅保留电弧特征信号的准确度难以保证^[24]。

本文从时效性和准确性指标进行方法对比。时效性指标采用算法运行时间作为评价标准, 准确性指标采用准确率作为评价标准。本文使用的计算机设备 Intel (R) Core (TM) i5-6200U CPU @ 2.30 GHz 2.40 GHz, 机带 RAM 4.00 GB, 64 位操作系统, Windows 10 家庭版, 版本号 20H2。

1) 时效性:

220 V、2~10 A 交流电下, 串联故障电弧短时间内就能产生 2 000~4 000 °C 的高温, 超过 0.5 A 就能够拉弧^[25]。因此, 串联故障电弧的识别对时效性要求很高。本文将 10 组串联故障电弧数据送入算法, 算法运行时间统计表如表 3 所示。

表 3 算法运行时间统计表

序号	时间	序号	时间
1	0.597 396 s	6	0.272 161 s
2	0.261 663 s	7	0.324 190 s
3	0.228 646 s	8	0.256 925 s
4	0.233 615 s	9	0.268 087 s
5	0.223 353 s	10	0.249 927 s
均值	0.291 596 s		

根据表 3 的时间统计, 识别方法可以在 0.3 s 左右的时间内实现故障电弧的识别, 满足《电气火灾监控系统第 4 部分: 故障电弧探测器》GB 14287.4 的规定要求。

2) 准确性:

串联故障电弧的识别不仅要求反应快速, 更要识别准确。将实验获取的 60 组串联电弧故障数据随机混入 600 组正常数据中, 组成测试集, 分别送入识别算法。串联电弧故障识别准确率如表 4 所示。

表 4 串联电弧故障识别结果准确率

类型	识别结果准确率		
	CEEMD-DTW	GLGCO-SVM	TDV-CNN
阻性串弧	97.5%	94.7% ^[22]	98% ^[23]
阻感串弧	95%		96% ^[23]
非线性串弧	91.9%		83% ^[23]
平均值	94.8%	94.7%	92.33%

根据表 4 的统计, 本文从三种负载类型识别结果准确

率及均值四个维度进行对比, 针对各类型串弧故障的识别准确率代表了单体识别的有效性, 识别结果准确率均值代表了对不同负载类型普适性。

CEEMD-DTW 方法对随机产生的故障数据均表现出较好的适应性, 对阻性串弧、阻感串弧、非线性串弧都具有 91% 以上的识别准确度。

在相同条件下, 将本文方法与 GLGCO-SVM 方法对比, 二者识别准确率均值类似, 但前者针对阻性负载串联故障电弧的识别优势明显, 且算法结构清晰简单, 可在嵌入式设备中实现, 可有效实现云边协同识别; 与 TDV-CNN 方法进行对比, 本文方法针对非线性负载串联故障电弧的识别优势明显, 且识别结果准确率均值也高于对比方法。由于 TDV-CNN 方法在池化阶段会丢失大量的数据特征, 对随机性较强、周期性较差的数据进行特征匹配时识别结果并不理想, 因此其针对非线性串弧表现出的随机性和非周期性特征识别效果较差, 导致识别准确率均值较低。

3 结束语

1) 本文依托监测线路高频电气参数提供了一种串联电弧故障识别方案, 不易受到外界温度、烟雾浓度等环境因素的影响, 满足时效性要求, 可信度较高。

2) 本文针对串联电弧故障的识别要求, 采用事件触发机制, 将事件前后向量差作为识别对象, 通过高斯拟合方法确定线路负载类型, 巧妙设置了一阶、二阶特征提取识别阈值, 利用 CEEMD-DTW 算法进行串联电弧故障识别, 普适性较强。

3) 本文主要以某一类型负载的串联电弧故障为研究对象。但实际中, 除大型或重要单一设备外, 线路监测对象复杂组合情况下, 其非线性特征可能会有变化, 实现准确的串联电弧故障识别仍然是这一领域的难点。本文方法应用于复杂组合负载情况时有待进一步分析和研究。

参考文献:

- [1] 2020 年全国火灾情况 [J]. 消防界 (电子版), 2021, 7 (3): 14-15.
- [2] 余琼芳. 基于小波分析及数据融合的电气火灾预报系统及应用研究 [D]. 秦皇岛: 燕山大学, 2013.
- [3] ZHAN W, S Balog Robert. Arc fault and flash detection in photovoltaic systems using wavelet transform and support vector machines [C] // 2016 IEEE 43rd Photovoltaic Specialists Conference, 2016: 3275-3280.
- [4] ZHAO Y Q, ZHANG X B, DONG Y J, et al. Characteristics Analysis and Detection of AC Arc Fault in SSPC based on Wavelet Transform [C] // 2016 IEEE/CSAA International Conference on Aircraft Utility Systems (AUS), 2016: 476-481.
- [5] DUAN P Y, XU L P, DING X D, et al. An arc fault diagnostic method for low voltage lines using the difference of wavelet coefficients [C] // Industrial Electronics and Applications, 2014: 401-405.
- [6] 赵雪花, 桑宇婷, 祝雪萍. 基于 CEEMD-GRNN 组合模型的

