

DOI: 10.19783/j.cnki.pspc.211131

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

杨帆¹, 宿磊¹, 杨志淳¹, 徐丙垠^{2,3}, 薛永端⁴, 王伟², 邹国锋²

(1. 国网湖北省电力有限公司电力科学研究院, 湖北 武汉 430077; 2. 山东理工大学电气与电子工程学院, 山东 淄博 255049; 3. 山东科汇电力自动化股份有限公司, 山东 淄博 255087; 4. 中国石油大学(华东)新能源学院, 山东 青岛 266580)

摘要: 针对低压线路中的串联故障电弧检测难题, 提出基于改进 CEEMDAN 分解与时空特征的串联故障电弧检测方法。首先, 采用 CEEMDAN 算法实现电流信号的完备分解, 并以各 IMF 分量的峭度指标、裕度指标、能量特征和能量熵特征为判定依据, 实现高频段信号粗选。然后, 提出空间尺度和时间尺度相融合的特征构建方法, 捕获各粗选高频 IMF 分量的局部特征, 增强电流特征对比度和判别力。最后, 采用子空间变换算法实现电流时空特征集合的二次降维, 并基于 SVM 实现串联故障电弧检测。实际试验证明, 所提算法的平均故障电弧检测准确率达 88.33%, 能够实现高效的串联故障电弧检测。

关键词: 串联故障电弧检测; CEEMDAN 分解; 频段粗选; 时空特征; 支持向量机

Series fault arc detection in low voltage power supply line based on improved CEEMDAN decomposition and spatial-temporal features

YANG Fan¹, SU Lei¹, YANG Zhichun¹, XU Bingyin^{2,3}, XUE Yongduan⁴, WANG Wei², ZOU Guofeng²

(1. Electric Power Research Institute of State Grid Hubei Electric Power Co., Ltd., Wuhan 430077, China; 2. School of Electrical and Electronic Engineering, Shandong University of Technology, Zibo 255049, China; 3. Shandong Kehui Power Automation Co., Ltd., Zibo 255087, China; 4. College of New Energy, China University of Petroleum (East China), Qingdao 266580, China)

Abstract: There is a problem of series arc fault detection in low voltage lines. Thus a series arc fault detection method based on improved CEEMDAN decomposition and spatial-temporal features is proposed. First, the CEEMDAN algorithm is used to complete the decomposition of the current signal, and the rough selection of the high-frequency signal is realized based on the kurtosis index, margin index, energy feature and energy entropy feature of each IMF component. Then, a feature construction method combining spatial and temporal scales is proposed to capture the local feature of each high-frequency IMF component. This enhances the contrast and discriminants of the current feature. Finally, some subspace transformation algorithms are used to implement the second dimension reduction of the current spatial-temporal feature set, and the series fault arc detection is realized based on SVM. The actual test shows that the average fault arc detection accuracy of the proposed algorithm is 88.33%, which is efficient for series fault arc detection.

This work is supported by the National Natural Science Foundation of China (No. 52077221).

Key words: series fault arc detection; CEEMDAN decomposition; rough selection of frequency band; spatial-temporal features; SVM

0 引言

低压供电线路中的线路绝缘老化损坏、接线端子

松脱等容易引发电弧故障。电弧故障伴生的局部高温极易引发电气火灾事故。电弧故障分为串联型和并联型, 其中, 串联电弧故障发生时, 由于其故障电流大小与负荷电流相仿^[1], 且故障电流波形特征与非线性负载负荷电流特征难以区分, 因此其成为电弧检测技术的热点和难点^[2-3]。

基金项目: 国家自然科学基金项目资助(52077221); 国网湖北省电力有限公司科技项目资助(52153220001V)

目前, 故障电弧检测方法主要分为两类: (1) 基于故障电弧产生的弧光、弧声、温度等物理特征实现的电弧检测; (2) 基于电弧电压信号或电流信号的时频域分析实现的电弧检测^[4]。由于故障电弧发生位置具有随机性, 因此第 1 类检测方法多用于电气开关柜中, 在线路故障电弧检测中的应用受到较大限制^[5-6]。而基于监测点电流、电压测量信号的时频域分析检测方法则成为该领域的研究热点^[7-8]。电流检测方法通过在待保护线路上游安装监测点, 可对其下游支路的电弧故障进行保护, 其适用性和灵活性更强, 因此, 相比于电压检测方法, 电流检测方法更加受到研究者的青睐。

线路发生串联电弧故障时, 电流信号呈现明显的非线性和非平稳性特征, 傅里叶变换和小波变换等时频分析法^[9-12]难以自适应捕获这些关键信息, 所以电弧检测准确性并未得到大幅提升。希尔伯特黄变换(Hilbert-Huang Transform, HHT)^[13]是一种典型的非线性、非平稳信号处理方法, 其核心是经验模态分解(Empirical Mode Decomposition, EMD), 能将复杂信号自适应地分解成若干本征模态函数(Intrinsic Mode Function, IMF)。EMD 分解方法的不足是其存在严重的模态混叠等问题, 进而影响 HHT 的性能^[14]。因此, 文献[15]提出了集成经验模态分解法(Ensemble Empirical Mode Decomposition, EEMD), 能在一定程度上抑制模态混叠, 还原信号本质。文献[16]提出了一种自适应噪声的完备经验模态分解(Complete Ensemble Empirical Mode Decomposition with Adaptive Noise, CEEMDAN), 该方法进一步提升了分解信号的精确度和完备性, 且大大减少了计算量, 但该方法在电弧电流信号分析中尚未得到应用。

近年来, 随着计算机运算能力不断提升, 机器学习算法在故障电弧特征提取和检测领域逐步获得应用^[17-20], 且电弧检测准确度得到一定提升。但这些算法多依赖于复杂的模型结构、高质量的标注数据或特殊的数据采集系统, 因此算法的适应性和灵活性不佳, 难以推广应用。

综上所述, 本文提出一种基于改进 CEEMDAN 分解和时空特征的串联故障电弧检测方法。首先, 提出一种带频率粗选的 CEEMDAN 分解策略, 基于 CEEMDAN 算法实现串联电弧电流信号分解, 获取完备的 IMF 分量; 以各 IMF 分量的峭度指标、裕度指标、能量特征和能量熵特征为判定依据, 确定基频边界, 实现各 IMF 分量的频段划分和高频段信号粗选。然后, 针对故障电弧所在高频段信号, 提出一种时空融合的特征提取算法, 确定基频 IMF 分量周期个数, 以周期个数为依据将不同尺度的高频

IMF 分量划分为多个时间区段; 计算 IMF 分量各时间区段的局部特征指标, 构建故障电弧电流特征库。最后, 采用子空间变换实现电流特征二次降维, 并采用支持向量机实现串联故障电弧检测。试验证明, 本文提出的融合 CEEMDAN 算法与高频信号粗选的分解策略以及时空融合特征构建算法, 能够有效捕获串联故障电弧的判别特征, 并基于支持向量机实现了故障电弧的可靠检测。

1 CEEMDAN 算法介绍

EMD 算法存在模态混叠的主要原因是信号的间歇现象。EEMD 算法将具有频率均匀分布特性的高斯白噪声加入信号, 使信号在不同尺度上变为连续, 从而克服信号间歇问题, 避免了模态混叠, 但该算法仅通过有限次的总体平均无法完全消除所引入的白噪声干扰。为克服 EEMD 算法导致的重构信号失真, CEEMDAN 算法在对原始信号进行经验模态分解的各阶段, 添加了自适应高斯白噪声来消除虚假信息干扰, 算法步骤如下所述。

1) 在原始信号 $x(t)$ 中添加高斯白噪声 $n_i(t)$, 加噪信号为 $x(t) + \gamma_0 n_i(t)$, 其中 γ_0 为噪声系数。利用 EMD 对加噪信号执行 I 次分解, 通过集成平均得到 CEEMDAN 第 1 个 IMF 分量和对应残差分量:

$$IMF_1(t) = \frac{1}{I} \sum_{i=1}^I IMF_{i1}(t) \quad (1)$$

$$r_1(t) = x(t) - IMF_1(t) \quad (2)$$

2) 定义 $EMD_j(\cdot)$ 是 EMD 分解的第 j 个模态函数。对加噪信号 $r_1(t) + \gamma_1 \cdot EMD_1[n_i(t)]$ 进行分解, 得到 CEEMDAN 的第 2 个 IMF 分量:

$$IMF_2(t) = \frac{1}{I} \sum_{i=1}^I EMD_1(r_1(t) + \gamma_1 \cdot EMD_1[n_i(t)]) \quad (3)$$

3) 计算 k 阶残差分量:

$$r_k(t) = r_{k-1}(t) - IMF_k(t) \quad (4)$$

对第 k 个信号 $r_k(t) + \gamma_k \cdot EMD_k[n_i(t)]$ 进行 EMD 分解, 每次添加白噪声后均分解至第一个 IMF 分量, 在此基础上, 计算 CEEMDAN 的第 $k+1$ 个 IMF 分量:

$$IMF_{k+1}(t) = \frac{1}{I} \sum_{i=1}^I EMD_1(r_k(t) + \gamma_k \cdot EMD_k[n_i(t)]) \quad (5)$$

4) 重复上述计算步骤, 直至残差分量不能继续分解, 得到 CEEMDAN 的所有 K 个 IMF 分量。此时, 剩余残差 $R(t)$ 为

$$R(t) = x(t) - \sum_{k=1}^K IMF_k(t) \quad (6)$$

因此, 初始信号被分解后可表示为

$$x(t) = \sum_{k=1}^K IMF_k(t) + R(t) \quad (7)$$

CEEMDAN 方法基于噪声辅助分析能够实现原始信号的完整重构。利用噪声系数自适应调整不同信噪比高斯噪声, 有效改善了 EMD 的分解效果。

2 电流信号特征计算与高频信号粗选

2.1 信号特征指标计算

经 CEEMDAN 分解获得的时频分量蕴含了故障电弧检测的关键信息, 但各频段信号变化复杂, 无法直接将电流波形数据用作电弧检测的决策特征。因此, 借鉴机械故障诊断中的特征构建方法^[21-22], 定义了针对 IMF 分量的 13 个统计特征指标以及能量特征、熵特征和能量熵特征, 构建形成 16 维的电流特征向量, 为故障电弧检测提供判定依据。

以时域电流为输入, 经 CEEMDAN 分解获得 K 个 IMF 分量, 假设每个分量包含 N 个采样点为 x_1, x_2, \dots, x_N , 表 1 所示为 13 个统计特征指标定义。

表 1 统计特征指标定义

Table 1 Definition of statistical feature indexes

特征指标	定义式
均值	$\bar{X} = \frac{1}{N} \sum_{i=1}^N x_i$
方差	$\sigma^2 = \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{X})^2$
均方根值	$X_{RMS} = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i)^2}$
方根幅值	$X_r = \left(\frac{1}{N} \sum_{i=1}^N x_i \right)^2$
平均幅值	$\bar{X}_a = \frac{1}{N} \sum_{i=1}^N x_i $
峰值	$X_p = \max(x_i)$
峭度	$K = \frac{1}{N-1} \sum_{i=1}^N \frac{(x_i - \bar{X})^4}{\sigma^4}$
偏度	$S = \frac{1}{N-1} \sum_{i=1}^N \frac{(x_i - \bar{X})^3}{\sigma^3}$
波形指标	$W_r = \frac{X_{RMS}}{ \bar{X} }$
峰值指标	$C_r = \frac{X_p}{X_{RMS}}$
脉冲指标	$I_r = \frac{X_p}{ \bar{X} }$
峭度指标	$K_r = \frac{K}{X_{RMS}^4}$
裕度指标	$L_r = \frac{X_p}{X_r}$

分解所得每个 IMF 分量信号的能量特征定义式为

$$E = \sum_{i=1}^N (x_i)^2 \quad (8)$$

每个 IMF 分量序列的熵特征为

$$H = - \sum_{i=1}^N P(x_i) \lg P(x_i) \quad (9)$$

式中, $P(\cdot)$ 代表概率。

每个 IMF 分量序列的能量熵特征为

$$H_{EN} = - \sum_{i=1}^N P_i \lg P_i \quad (10)$$

式中, $P_i = E_i / \sum_{i=1}^K E_i$, E_i 表示第 i 个 IMF 分量的能量。

经过上述运算, 每个 IMF 分量可计算得到一个 16 维的特征向量, 对所有 IMF 分量进行特征计算可得到每个电流信号的特征矩阵。

2.2 高频信号粗选

研究发现, 峭度指标、裕度指标、能量特征和能量熵特征对于信号波动较为敏感, 适合作为判断信号状态的依据。当峭度指标、裕度指标为最小值, 能量特征和能量熵特征为最大值时, 对应 IMF 分量的频率与电弧电流信号的频率相同, 即该频率分量对应于电弧电流组成成分中的基频分量。

以基频 IMF 分量为分界, 可将不同频率的 IMF 分量划分为高频段和低频段信号。研究表明, 引起故障电弧的电流信号通常出现在高频段, 因此, 在确定频率分界后, 只需针对 CEEMDAN 分解所得的高频段信号进行特征值计算和二次特征降维。

本文提出的融合 CEEMDAN 分解与高频段信号粗选的方法, 避免了低频段信号的干扰, 缩小了从 IMF 分量中挖掘电弧特征的信号范围, 能降低特征计算和降维的复杂度, 提升了电弧检测的效率。

3 时空特征计算与故障电弧检测

3.1 时空融合的特征计算

高频段各 IMF 分量与电弧电流采样点数相同, 将各分量包含的 N 个数据作为整体参与特征指标计算, 形成的特征向量能够反映信号的空间尺度变化, 但不能充分体现各分量电流信号时间维度的局部变化。分析高频段 IMF 分量发现, 具有显著周期性的时间维度局部特征能更加细致地表达信号的实时变化, 对于分析由故障电弧引起的高频信号波动具有明显的优势和显著的区分度。

因此, 为了更好地刻画和利用信号的空间尺度特征和时间尺度局部特征, 并实现电弧电流的准确检测, 本文提出一种时空融合的信号特征指标计算

方法。该算法首先需要确定基频 IMF 分量的周期个数 P , 并以该周期个数为划分依据, 将高频段各尺度的 IMF 分量划分为 P 个时间区段, 从而形成 P 个时间尺度; 然后按照 2.1 节定义, 计算各时间区段(每个区段包含 N/P 个数据点)的局部特征指标。时空融合特征的计算步骤如图 1 所示。

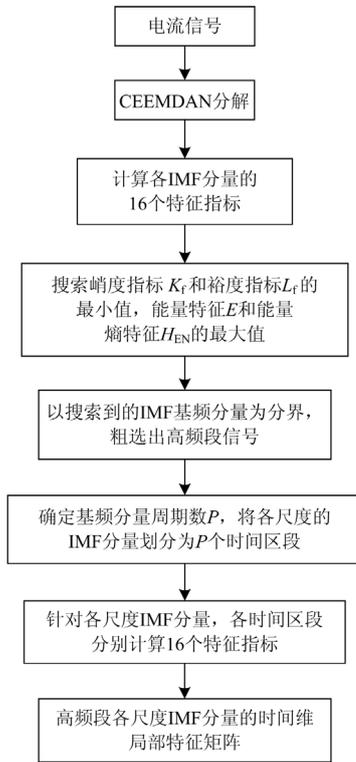


图 1 时空融合特征计算步骤

Fig. 1 Calculation steps of spatio-temporal fusion features

3.2 故障电弧检测

空间尺度与时间尺度融合形成的特征中仍包含大量冗余信息, 甚至干扰信息。因此, 针对初步计算所得的电弧电流特征执行二次特征提取与降维, 对于提升特征判别能力至关重要。子空间映射是通过数学变换将特征向量从原空间映射到像空间, 映射后像空间中的特征向量具有更低的维数和更显著的判别能力。当前, 经典的子空间特征提取方法包括 PCA、LDA、ICA、KPCA、KLDA 等^[23]。本文选取线性子空间映射法 PCA、LDA, 和非线性子空间映射法 KPCA、KLDA 进行电弧电流特征的二次提取。

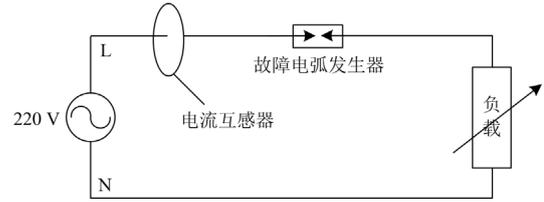
支持向量机(Support Vector Machine, SVM)是一种经典二分类器, 在解决小样本、非线性及高维模式识别问题中表现优异, 能在有限特征信息情况下最大限度地挖掘样本特征隐含的决策信息, 在故障诊断领域应用广泛。因此, 本文选取 SVM 作为

串联故障电弧检测的分类器。

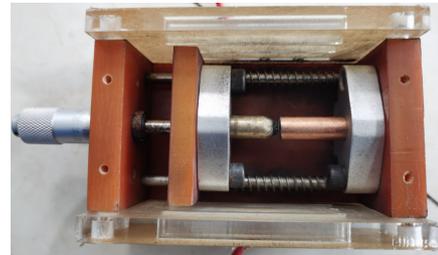
4 试验验证

4.1 电弧信号采集平台

图 2 展示了本文搭建的串联故障电弧发生电路, 使用带宽 200 kHz 的 LPCT 作为电流传感器, 故障电弧发生器采用直径为 10.0 mm 的铜电极作为动触头, 直径为 8.0 mm 的石墨电极作为参考静触头, 通过控制电极间隙产生电弧。



(a) 串联电弧故障发生电路原理



(b) 串联电弧故障发生器

图 2 串联故障电弧发生电路

Fig. 2 Series fault arc generation circuit

4.2 电流数据集构建

基于图 2 所示故障电弧发生采集电路, 使用示波器采集电流信号, 采样频率为 50 kHz, 采样长度设定为 20 ms。不同负载下的电流数据集如表 2 所示。

表 2 不同负载下的电流数据集

Table 2 Current data sets under different loads

负载类型	正常数据(组)	故障数据(组)
400 W 电炉	10	30
800 W 电炉	10	30
电脑	10	30
微波炉	10	30

考虑到实际线路中的负载分为阻性、阻感性和非线性三类。试验选取 800 W 电炉作为纯阻性负载; 电炉工作于 400 W 时, 其工作于半波整流状态; 因此 800 W 和 400 W 电炉基本涵盖了阻性负载的电流特征。电脑为非线性负载, 其电流波形可代表绝大部分开关电源负载。微波炉则属于含有电感较多的非线性负载, 可代表绝大多数阻感性负载的电流特性。以上 4 种负载均为生活中使用频率较高的家电,

且可代表大多数负载情况，具备典型性。试验中，分别采集了每种负载下的 10 组正常电流数据和 30 组故障电流数据。不同负载下的故障电弧电流波形如图 3 所示，其中前 5 个周波无故障，后 5 个周波发生故障。

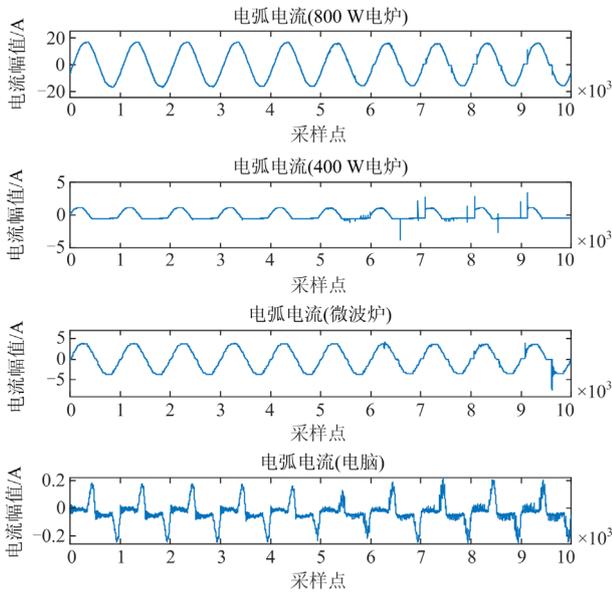


图 3 不同负载下故障电弧电流波形

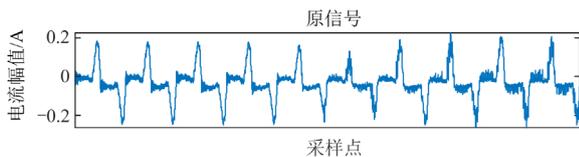
Fig. 3 Fault arc current waveforms under different loads

观察图 3，电弧故障发生后，电流波形不同程度地出现了零休、高频毛刺和幅值降低现象，同时发现，受到负载类型影响，难以建立适合多种负载的通用故障特征。

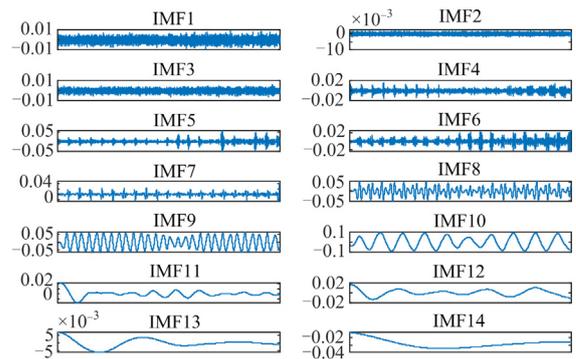
试验中，随机任意选取 4 种负载的 5 组正常电流数据和 20 组故障电弧电流数据，共 100 组数据用作子空间变换算法和 SVM 的训练样本。选取剩余的 5 组正常电流和 10 组故障电弧电流数据，共 60 组数据作为测试样本。通过 10 次交叉试验，获得平均准确度作为所提算法的性能评价指标。

4.3 电流信号的分解试验

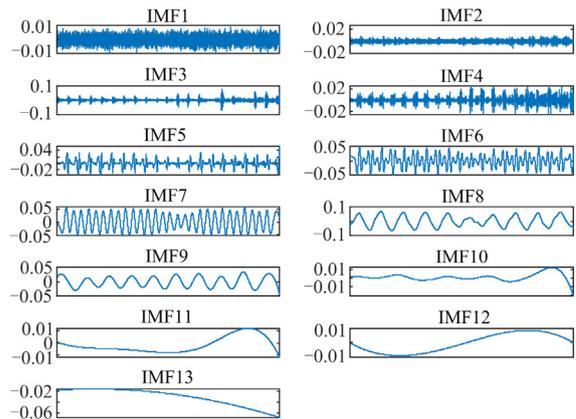
为说明 CEEMDAN 相比于 EEMD 和 EMD 分解的优势，本文采用 CEEMDAN 策略对电弧电流信号分解的同时，采用 EEMD 和 EMD 进行了分解效果对比，故障电弧电流波形及分解结果如图 4 所示。其中，图 4(a)为电脑负载下的故障电弧电流波形，图 4(b)、(c)、(d)分别为不同分解算法下的分解结果。



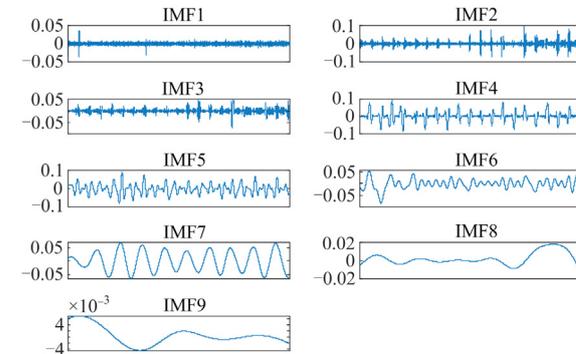
(a) 电脑负载故障前后电流波形



(b) CEEMDAN分解结果



(c) EEMD分解结果



(d) EMD分解结果

图 4 故障电弧电流波形及分解结果展示

Fig. 4 Display of fault arc current and decomposition results

三种分解结果显示，EMD 算法将电流自适应地分解为 9 个分量；EEMD 算法将电流波形分解为 13 个分量；而 CEEMDAN 算法将电流信号自适应地分解为 14 个分量。显然，CEEMDAN 算法实现了电流信号在不同频率范围内更加细致完备的分解。试验发现，针对 4 种负载下的电流数据，通过 CEEMDAN 分解均能获得 12~14 个不同频率的 IMF 分量，信号分解的完备性较好，有效克服了 EMD 算法的模态混叠和 EEMD 算法的噪声干扰。

图 4(b)分解结果显示, IMF10 分量的频率与原始电流信号的频率一致, 对应基频成分, IMF1—IMF9 为高频成分, IMF11—IMF14 为低频成分。各分量可清晰划分, 表明不同分量间不存在模态混叠问题。图 4(c)显示, 分量 IMF8 和 IMF9 的频率与原始电流信号频率基本一致, 可作为基频成分, 但 IMF8 与 IMF9 具有相同的频率, 表明发生了模态混叠。另外, IMF1—IMF7 为高频成分, IMF10—IMF13 为低频成分, 在高频段和低频段也分别存在不同程度的混叠现象, 例如 IMF11 与 IMF12 的混叠较为明显。这表明基于 EEMD 的分解无法完全克服模态混叠的干扰。观察图 4(d)可知, EMD 分解所得分量的完备性明显不足, 且所得分解结果间存在混叠现象。

另外, 在 CEEMDAN 分解中, 分量 IMF4、IMF5 和 IMF6 波形在电弧发生前后的时间维度上存在显著差异, 特别是 IMF5 和 IMF6 具有良好的区分度。

在 EEMD 分解中, 分量 IMF4 波形在电弧发生前后也具有一定差异, 但区分度的显著性不强。在 EMD 分解中, 分量 IMF2 的波形在电弧发生前后形成了明显的差异, 具备一定的判别能力。综合比较三种分解结果, CEEMDAN 分解算法在克服模态混叠问题中具有明显的优势, 且分解所得分量信号对故障电弧的判别力更强。

4.4 电流特征库构建

为了对 IMF 分量特征做有效的数学描述, 同时降低故障检测中的运算复杂度, 本文采用 8 个有量纲统计特征、5 个无量纲统计特征, 以及能量特征、熵特征和能量熵特征, 共 16 个特征作为 IMF 分量信号的特征描述。以图 4(b)分解结果为例, 14 个 IMF 分量, 每个分量表示为 1×16 特征向量。因此, 一组原始电流信号可用 14×16 维特征矩阵进行描述。不同 IMF 分量的特征值计算结果如表 3 所示。

表 3 不同 IMF 分量的特征值计算结果

Table 3 Calculation results of eigenvalues of different IMF components

名称	均值	方差	均方根值	方根幅值	平均幅值	峰值	峭度	偏度
IMF1	-3.65×10 ⁻⁶	4.91×10 ⁻⁶	2.23×10 ⁻³	3.11×10 ⁻⁶	0.001 8	0.009 5	3.10	-0.019
IMF2	-7.10×10 ⁻⁶	2.72×10 ⁻⁷	5.20×10 ⁻⁴	1.69×10 ⁻⁷	0.000 41	0.007 7	7.60	-0.32
IMF3	-1.53×10 ⁻⁶	2.18×10 ⁻⁶	1.53×10 ⁻³	1.37×10 ⁻⁶	0.001 2	0.008 0	3.27	-0.043
IMF4	-1.09×10 ⁻⁶	8.24×10 ⁻⁶	2.90×10 ⁻³	4.16×10 ⁻⁶	0.002 0	0.017	6.31	0.044
IMF5	1.29×10 ⁻⁵	6.61×10 ⁻⁵	8.14×10 ⁻³	2.49×10 ⁻⁵	0.005 0	0.057	11.48	0.018
IMF6	6.01×10 ⁻⁶	3.59×10 ⁻⁵	6.01×10 ⁻³	1.65×10 ⁻⁵	0.004 1	0.025	5.52	0.040
IMF7	6.12×10 ⁻⁶	4.02×10 ⁻⁵	6.30×10 ⁻³	1.67×10 ⁻⁵	0.004 1	0.041	7.27	0.067
IMF8	-6.96×10 ⁻⁵	4.91×10 ⁻⁴	2.20×10 ⁻²	3.07×10 ⁻⁴	0.017 5	0.056	2.69	0.002 8
IMF9	-6.71×10 ⁻⁴	1.40×10 ⁻³	3.71×10 ⁻²	1.14×10 ⁻³	0.033	0.066	1.66	0.025
IMF10	-1.30×10 ⁻³	3.13×10 ⁻³	5.53×10 ⁻²	2.38×10 ⁻³	0.049	0.095	1.71	0.041
IMF11	1.92×10 ⁻⁴	3.36×10 ⁻⁵	5.80×10 ⁻³	1.44×10 ⁻⁵	0.003 8	0.021	6.87	0.65
IMF12	-1.61×10 ⁻⁴	3.79×10 ⁻⁵	6.21×10 ⁻³	2.46×10 ⁻⁵	0.005 0	0.016	2.74	0.061
IMF13	-1.92×10 ⁻⁴	8.00×10 ⁻⁶	2.78×10 ⁻³	4.24×10 ⁻⁶	0.002 1	0.007 1	3.38	0.008 7
IMF14	-2.8×10 ⁻²	3.29×10 ⁻⁵	2.88×10 ⁻²	7.77×10 ⁻⁴	0.028	0.035	3.44	1.018

名称	波形指标	峰值指标	脉冲指标	峭度指标	裕度指标	能量特征	熵特征	能量熵特征
IMF1	1.26	4.30	5.41	3.07×10 ³	1.29×10 ¹¹	0.049	2.37	0.005 9
IMF2	1.27	14.68	18.62	4.53×10 ⁴	1.03×10 ¹⁴	0.002 7	1.31	0.000 46
IMF3	1.26	5.42	6.84	5.86×10 ³	6.88×10 ¹¹	0.022	2.12	0.002 9
IMF4	1.41	5.95	8.38	4.1×10 ³	9.29×10 ¹⁰	0.081	1.86	0.009 5
IMF5	1.63	7.06	11.50	2.3×10 ³	2.63×10 ⁹	0.665	1.53	0.051
IMF6	1.48	4.25	6.27	1.54×10 ³	4.28×10 ⁹	0.364	2.25	0.033
IMF7	1.55	6.40	9.92	2.42×10 ³	4.49×10 ⁹	0.406	1.93	0.034
IMF8	1.26	2.51	3.17	180.62	1.12×10 ⁷	5.01	3.029	0.215
IMF9	1.14	1.75	1.99	60.54	8.48×10 ⁵	13.96	3.30	0.342
IMF10	1.14	1.71	1.94	39.70	1.81×10 ⁵	30.11	3.31	0.344
IMF11	1.53	3.67	5.61	1.48×10 ³	6.09×10 ⁹	0.40	2.36	0.030
IMF12	1.24	2.57	3.19	642.69	1.90×10 ⁹	0.41	3.01	0.033
IMF13	1.38	2.50	3.44	1.67×10 ³	5.23×10 ¹⁰	0.057	2.86	0.012 4
IMF14	1.021	1.22	1.24	44.63	5.25×10 ⁶	7.155	2.76	0.259

表 3 数据表明, 16 个不同的特征指标展现了各 IMF 分量在尺度空间的变化情况, 通过比较各分量的峭度指标、裕度指标、能量特征、能量熵特征, 能清晰地判断出 IMF10 为基频分量。以 IMF10 为分界, 则 IMF1—IMF9 对应高频段信号, IMF11—IMF14 对应低频段信号。显然, 该判断结果与直接观察图 4(b)得到的结论完全相同, 证明了本文所提信号粗选策略的有效性。

试验采集电流信号均包含 10 个周期, 因此根据时空融合特征计算方法, 高频段每个 IMF 分量被划分为 10 个不交叠的时间区段, 并针对每个区段计算上述的 16 个特征指标。表 4 展示了 IMF6 分量的 10 个时间区段特征值计算结果。该特征综合考虑了不同空间尺度各 IMF 分量所蕴含识别特征的多样性和同一空间尺度中不同时间区段关键局部特征的判别性, 实现了故障电弧复杂关键特征有效提取。

另外, 采用通用性较强的 16 个特征指标构建电流特征, 提升了电流信号故障特征的完备性和适应性。

经过分区段特征计算, 每个 IMF 分量可用 160 维的局部特征表达。假设高频分量个数为 N_H , 即 IMF 分量的空间尺度为 N_H , 则原始电流信号最终可用 $160 \times N_H$ 的时空融合特征矩阵进行描述。

由于不同电流信号经过 CEEMDAN 分解获得的高频分量个数可能不同(但高频分量个数均在 5 个以上), 因此构建的时空融合特征矩阵维度并不完全匹配。鉴于子空间变换算法对各电流特征维数必须匹配的需求, 本文试验中对所有电流信号的时空融合特征执行了下采样预处理, 将特征维数统一归一化为 800 维, 即一组电流信号用 800 维的时空融合特征向量表征。因此, 4 种负载下的 160 组电流数据, 最终形成规模为 160×800 的电流特征库。

表 4 IMF6 分量的 10 个时间区段特征值计算结果

Table 4 Calculation results of the eigenvalues of IMF6 component in 10 time intervals

名称	均值	方差	均方根值	方根幅值	平均幅值	峰值	峭度	偏度
区段 1	-4.73×10^{-5}	1.26×10^{-5}	0.003 6	6.29×10^{-6}	0.002 5	0.012 9	4.293	-0.174
区段 2	1.34×10^{-6}	1.46×10^{-5}	0.003 8	7.33×10^{-6}	0.002 7	0.014 2	4.089	0.093
区段 3	-2.34×10^{-5}	1.56×10^{-5}	0.003 9	7.90×10^{-6}	0.002 8	0.012 4	4.013	0.128
区段 4	-3.31×10^{-5}	1.39×10^{-5}	0.003 7	6.65×10^{-6}	0.002 6	0.011 5	4.101	-0.011
区段 5	5.68×10^{-5}	2.45×10^{-5}	0.005 0	1.09×10^{-5}	0.003 3	0.020 6	6.645	-0.003 6
区段 6	2.38×10^{-7}	5.45×10^{-5}	0.007 4	2.48×10^{-5}	0.005 0	0.022	4.467	0.014 1
区段 7	-8.55×10^{-5}	4.10×10^{-5}	0.006 4	1.94×10^{-5}	0.004 4	0.021 8	4.835	0.043 3
区段 8	-3.76×10^{-6}	5.41×10^{-5}	0.007 4	2.64×10^{-5}	0.005 1	0.021 4	4.313	-0.006 9
区段 9	8.49×10^{-5}	5.29×10^{-5}	0.007 3	3.06×10^{-5}	0.005 5	0.023 1	3.659	-0.070 8
区段 10	1.10×10^{-4}	7.54×10^{-5}	0.008 7	4.41×10^{-5}	0.006 6	0.025 4	3.443	0.113 6

名称	波形指标	峰值指标	脉冲指标	峭度指标	裕度指标	能量特征	熵特征	能量熵特征
区段 1	1.415	3.62	5.128	2 043.72	2.69×10^{10}	0.012 6	2.56	0.118
区段 2	1.409	3.719	5.24	1 935.35	1.93×10^{10}	0.014 6	2.55	0.130
区段 3	1.404	3.137	4.40	1 565.86	1.65×10^{10}	0.015 6	2.67	0.136
区段 4	1.448	3.075	4.45	1 726.83	2.11×10^{10}	0.013 9	2.60	0.126
区段 5	1.502	4.163	6.25	1 897.97	1.11×10^{10}	0.024 5	2.23	0.183
区段 6	1.483	2.995	4.44	892.63	1.50×10^{10}	0.054 5	2.25	0.286
区段 7	1.455	3.408	4.96	1 126.76	2.87×10^9	0.041 1	2.48	0.248
区段 8	1.432	2.914	4.17	813.15	1.48×10^9	0.054 1	2.69	0.285
区段 9	1.315	3.180	4.18	755.59	1.31×10^9	0.052 9	2.74	0.282
区段 10	1.308	2.931	3.83	577.44	6.06×10^8	0.075 4	2.80	0.328

4.5 电流特征二次降维与故障电弧检测试验

经过上述处理, 160×10000 维的原始电流数据被转化为 160×800 维的特征集合, 但特征集合中仍包含较多的冗余信息和干扰信息, 因此, 本文采用子空间变换法对电流时空特征集合执行二次特征提取, 以挖掘更高区分度的电流特征。

故障电弧检测试验中采用 SVM 作为检测器。SVM 核函数采用高斯核函数, 通过交叉验证网格搜索方法确定了 SVM 的最优惩罚因子和核函数可调参数, 其中确定的 SVM 惩罚因子取值为 10, 核函数参数取值为 0.15。

线性变换法 PCA 和 LDA 的主要影响因素为特

征提取过程中所保留的特征维数 d ; 非线性变换法 KPCA 和 KLDA 的影响因素包括保留特征维数 d 和核函数可调参数 σ 。本文对以上影响因素进行了比较试验, 以确定各算法最佳性能时的参数设置。交叉试验中 PCA 和 LDA 特征维数对检测准确率的影响如图 5 所示。交叉试验中 KPCA 和 KLDA 在不同参数下的检测准确率如图 6 所示。

观察图 5, PCA 和 LDA 受特征维数影响, 电弧电流检测准确率曲线具有相似的变化趋势。当维数低于 25 时, 检测准确率普遍较低, 该阶段随着维数逐渐增加, 特征中包含的有效信息逐步增多, 所以检测准确率的上升速度较快。当维数达到 30~40 维时, 检测准确率达到较高的数值, 但受特征有效性影响, 存在小幅波动。当维数增加超过 45 维时, 保留特征中会引入干扰信息, 所以检测准确率呈现小幅下降; 该阶段随着维数继续增加, 检测准确率整体比较稳定, 维持在 75%~80%。

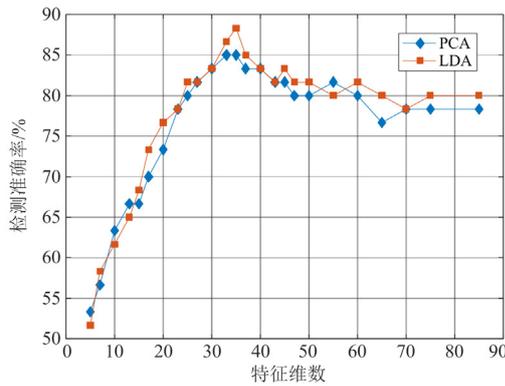


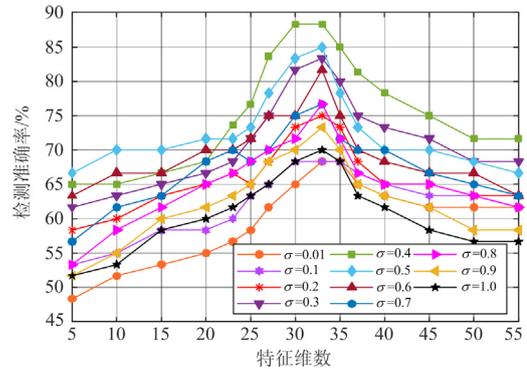
图 5 PCA 和 LDA 特征维数对检测准确率的影响

Fig. 5 Influence of feature dimensions of PCA and LDA on detection accuracy

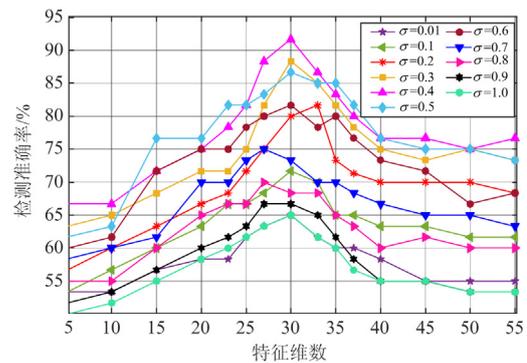
由于 LDA 属于有监督算法, 而 PCA 为无监督特征提取算法, LDA 比 PCA 更容易捕获强判别力特征, 因此表现出更加优异的检测性能。特征保留维数为 33 时, PCA-SVM 得到最优检测准确率为 85%; 特征保留维数为 35 时, LDA-SVM 获得最优检测准确率为 88.33%。经过 10 次交叉验证试验, 最终获得的 PCA-SVM 算法的平均检测准确度为 77.2%, LDA-SVM 算法的平均检测准确度为 81.5%。

图 6(a)和图 6(b)展示了核函数可调参数不同取值和特征保留维数对检测准确率的影响。比较发现, 特征保留维数对检测准确率的影响与线性子空间变换法的变化情况相似。核函数可调参数对于纵向提升检测准确率起到了关键作用。如图 6 所示: KPCA 算法可调参数的最优取值范围为 0.4~0.5, 最佳特征保留维数为 30, 此时最高检测准确率达 88.33%;

KLDA 算法可调参数最优取值范围为 0.3~0.4, 最佳特征保留维数为 30, 此时最高检测准确率达到 91.67%。综合分析: 试验中确定 KPCA 算法核函数可调参数取值设置为 0.4; KLDA 算法核函数可调参数取值设置为 0.35; 两种算法的最佳特征保留维数均为 30。



(a) KPCA 算法不同参数对检测准确率的影响



(b) KLDA 算法不同参数对检测准确率的影响

图 6 KPCA 和 KLDA 不同参数下的检测准确率

Fig. 6 Detection accuracy of KPCA and KLDA under different parameters

为证明所提算法检测准确率的可靠性和有效性, 试验中开展了 10 次交叉验证试验, 并计算平均检测准确率作为最终性能评价。10 次交叉验证试验的检测准确率如图 7 所示。

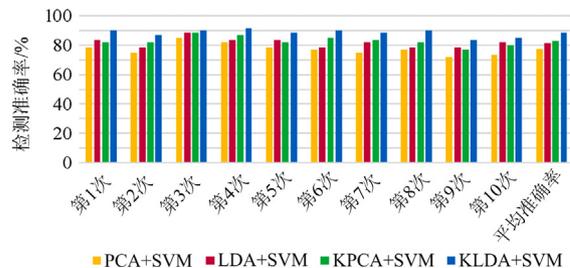


图 7 交叉验证试验的检测准确率

Fig. 7 Detection accuracy of cross validation test

在第 1 次和第 9 次试验中, LDA-SVM 算法的检测性能优于 KPCA-SVM 算法, 但总体平均检测准确率 KPCA-SVM 为 82.7%, 优于 LDA-SVM 的 81.5%。这表明非线性子空间变换的特征提取能力优于线性子空间变换, 同时说明本文构建的时空融合特征包含较多的非线性信息。另外, KLDA-SVM 算法的平均检测准确率最高, 达到 88.33%。KLDA 算法的优势在于监督信息指导, 在同样保留 30 维特征情况下, KLDA 算法捕获特征的区分度更显著、判别力更强。因此, 与 KPCA-SVM 算法相比, KLDA-SVM 检测准确率提高了约 5%。

5 结论

为准确高效地实现串联故障电弧检测, 提出基于改进 CEEMDAN 分解与时空特征的检测算法。搭建串联电弧发生平台, 构建 4 种典型负载的电弧电流数据集。提出一种频段粗选策略, 与 CEEMDAN 算法结合, 实现电弧故障高频信号所在频段选取。提出一种空间和时间尺度相融合的特征构建方法, 实现多尺度高频信号的时间维局部特征提取, 增强了电流特征的对比度和判别力。采用子空间变换实现二次特征提取和降维, 并利用支持向量机完成串联故障电弧检测。所提算法平均故障电弧检测准确率达 88.33%, 证明了所提算法的有效性, 为故障电弧检测技术和装置设计提供了重要参考。

参考文献

[1] 刘官耕, 杜松怀, 苏娟, 等. 低压电弧故障防护技术研究与发展趋势[J]. 电网技术, 2017, 41(1): 316-324.
LIU Guangeng, DU Songhuai, SU Juan, et al. Research on LV arc fault protection and its development trends[J]. Power System Technology, 2017, 41(1): 316-324.

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

[3] 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.

[4] 卢其威, 王涛, 李宗睿, 等. 基于小波变换和奇异值分解的串联电弧故障检测方法[J]. 电工技术学报, 2017, 32(17): 208-217.
LU Qiwei, WANG Tao, LI Zongrui, et al. Detection method of series arcing fault based on wavelet transform and singular value decomposition[J]. Transactions of China Electrotechnical Society, 2017, 32(17): 208-217.

[5] 汪金刚, 林伟, 王志, 等. 基于紫外检测的开关柜电弧在线检测装置[J]. 电力系统保护与控制, 2011, 39(5): 128-133.
WANG Jingang, LIN Wei, WANG Zhi, et al. Online detecting device for switchgear arc based on ultraviolet detection[J]. Power System Protection and Control, 2011, 39(5): 128-133.

[6] 潘本仁, 魏超, 桂小智, 等. 便携式电弧光保护测试仪的设计及应用[J]. 电力系统保护与控制, 2020, 48(13): 149-155.
PAN Benren, WEI Chao, GUI Xiaozhi, et al. Development and application of a portable arc protection tester[J]. Power System Protection and Control, 2020, 48(13): 149-155.

[7] 张冠英, 张艳娇, 赵远, 等. 基于高斯过程分类的串联直流电弧故障检测[J]. 高压电器, 2020, 56(4): 1-7, 14.
ZHANG Guanying, ZHANG Yanjiao, ZHAO Yuan, et al. Detection method of series DC arc fault based on Gaussian process classification[J]. High Voltage Apparatus, 2020, 56(4): 1-7, 14.

[8] 陈照, 王尧, 牛峰, 等. 基于神经网络和 D-S 证据理论的故障电弧检测[J]. 高压电器, 2019, 55(3): 29-36.
CHEN Zhao, WANG Yao, NIU Feng, et al. Fault arc detection based on neural network and D-S evidence theory[J]. High Voltage Apparatus, 2019, 55(3): 29-36.

[9] HADZIEFENDIC N, KOSTIC M, RADAKOVIC Z. Detection of series arcing in low-voltage electrical installations[J]. European Transactions on Electrical Power, 2009, 19(3): 423-432.

[10] 赵志宏, 杨绍普, 刘永强. 多小波系数特征提取方法在故障诊断中的应用[J]. 振动. 测试与诊断, 2015, 35(2): 276-280.
ZHAO Zhihong, YANG Shaopu, LIU Yongqiang. Application of feature extraction method in fault diagnosis based on multi-wavelet coefficients[J]. Journal of Vibration, Measurement & Diagnosis, 2015, 35(2): 276-280.

[11] ARTALE G, CATALIOTTI A, NUCCIO V C S, et al. A set of indicators for arc faults detection based on low

- frequency harmonic analysis[C] // 2016 IEEE International Instrumentation and Measurement Technology Conference (I2MTC), May 23-26, 2016, Taipei, Taiwan, China: 1-6.
- [12] 晏坤, 马尚, 王伟, 等. 基于小波分析和 Cassie 模型的低压串联电弧放电检测及故障保护仿真研究[J]. 电器与能效管理技术, 2019(18): 48-52, 67.
YAN Kun, MA Shang, WANG Wei, et al. Simulation and research of low voltage series arc discharge detection and fault protection based on Cassie model and wavelet analysis[J]. Electrical & Energy Management Technology, 2019(18): 48-52, 67.
- [13] HUANG N E, SHEN Z, LONG S R, et al. The empirical mode decomposition and the Hilbert spectrum for non linear non-stationary time series analysis[J]. Proceedings of the Royal Society, 1998, 454(1971): 903-995.
- [14] RILLING G, FLANDR N P, GONCALVES P. On empirical mode decomposition and its algorithms[C] // IEEE-EURASIP Workshop on Nonlinear Signal and Image Processing, NSIP-03, 2003, Gradoli, Italy: 9-11.
- [15] WU Z H, HUANG N E. Ensemble empirical mode decomposition: a noise-assisted data analysis method[J]. Advances in Adaptive Data Analysis, 2009, 1(1): 1-41.
- [16] TORRES M E, COLOMINAS M A, SCHLOTTH-AUER G, et al. A complete ensemble empirical mode decomposition with adaptive noise[C] // 2011 IEEE International Conference on Acoustics, Speech and Signal Processing, May 22-27, 2011, Wuhan, China: 4144-4147.
- [17] MUSA M H H, HE Zhengyou, FU Ling, et al. A cumulative standard deviation sum based method for high resistance fault identification and classification in power transmission lines[J]. Protection and Control of Modern Power Systems, 2018, 3(3): 291-302.
- [18] 陈奎, 陈博博. 基于改进暂态相关分析和支持向量机的电弧故障选线研究[J]. 电力系统保护与控制, 2016, 44(24): 66-73.
CHEN Kui, CHEN Bobo. Research on arc fault line selection based on improved transient correlation analysis and support vector machine[J]. Power System Protection and Control, 2016, 44(24): 66-73.
- [19] 郭凤仪, 高洪鑫, 唐爱霞, 等. 局部二值模式直方图匹配的串联故障电弧检测及选线[J]. 电工技术学报, 2020, 35(8): 1653-1661.
GUO Fengyi, GAO Hongxin, TANG Aixia, et al. Series arc fault detection and line selection based on local binary pattern histogram matching[J]. Transactions of China Electrotechnical Society, 2020, 35(8): 1653-1661.
- [20] 陈烜, 冷继伟, 李海峰. 基于全相位谱和深度学习的串联故障电弧识别方法[J]. 电力系统保护与控制, 2020, 48(17): 1-8.
CHEN Heng, LENG Jiwei, LI Haifeng. Series fault arc recognition method based on an all-phase spectrum and deep learning[J]. Power System Protection and Control, 2020, 48(17): 1-8.
- [21] 辜志强, 林月叠. 基于改进 LMD 和综合特征指标的滚动轴承故障诊断[J]. 合肥工业大学学报(自然科学版), 2021, 44(2): 145-150.
GU Zhiqiang, LIN Yuedie. Fault diagnosis of rolling bearing based on improved LMD and comprehensive characteristic index[J]. Journal of Hefei University of Technology (Natural Science Edition), 2021, 44(2): 145-150.
- [22] 蒋玲莉, 谭鸿创, 李学军, 等. 基于 CEEMDAN 排列熵与 SVM 的螺旋锥齿轮故障识别[J]. 振动、测试与诊断, 2021, 41(1): 33-40.
JIANG Lingli, TAN Hongchuang, LI Xuejun, et al. Fault diagnosis of spiral bevel gear based on CEEMDAN permutation entropy and SVM[J]. Journal of Vibration, Measurement & Diagnosis, 2021, 41(1): 33-40.
- [23] KEMPFERT K C, WANG Yishi, CHEN Cuixian, et al. A comparison study on nonlinear dimension reduction methods with kernel variations: visualization, optimization and classification[J]. Intelligent Data Analysis, 2020, 24(2): 267-290.

收稿日期: 2021-08-19; 修回日期: 2021-11-09

作者简介:

杨帆(1982—), 男, 博士, 高级工程师, 研究方向为智能配电网与故障检测; E-mail: yangf_82@163.com

宿磊(1989—), 男, 硕士, 高级工程师, 研究方向为智能配电网及信息通信安全防护技术; E-mail: sulei@me.com

杨志淳(1987—), 男, 博士, 高级工程师, 研究方向为智能配电网及信息物理融合技术; E-mail: yangzhichun3600@163.com

邹国锋(1984—), 男, 通信作者, 博士, 讲师, 研究方向为智能信息处理, 低压线路故障检测与诊断技术等。E-mail: zgf841122@163.com

(编辑 魏小丽)