

DOI: 10.13382/j.jemi.B2205132

融合 CEEMDAN 分解与敏感 IMF 精选的 串联电弧故障检测*

宿磊¹ 沈煜¹ 杨帆¹ 徐丙垠^{2,3} 薛永端⁴ 王玮² 邹国锋²

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

摘要:针对串联电弧故障检测困难,以及基于分解策略的检测方法难以捕获敏感判别分量的问题,提出一种融合自适应噪声的完备经验模态分解(CEEMDAN)和敏感本征模态函数(IMF)精选的串联电弧故障检测方法。本方法采用CEEMDAN算法对故障电弧电流进行完备分解;并定义了电弧电流的12个特征指标,以敏感性较强的峭度指标和能量特征作为判定依据,从而实现了IMF分量的频段划分;在此基础上,提出了基于时间窗的特征计算方法,通过获取各高频IMF分量的时间维度局部特征,并通过比较方差、均方根值等特征指标实现敏感IMF分量的准确选取。最后,针对电流特征集,采用主成分分析实现二次降维,并基于支持向量机(SVM)实现串联电弧故障检测。实验证明了所提方法的可行性和电弧故障检测的有效性。

关键词: 电弧检测; CEEMDAN 分解; 频段划分; 敏感 IMF 选取; 时间窗特征计算; 支持向量机

中图分类号: TM501.2 **文献标识码:** A **国家标准学科分类代码:** 510.40

Series arc fault detection combining CEEMDAN decomposition and sensitive IMF selection

Su Lei¹ Shen Yu¹ Yang Fan¹ 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: Aiming at the difficulty of series arc fault detection and the difficulty of detection method based on decomposition strategy to capture sensitive discriminant components, a series fault arc detection method combining complete ensemble empirical mode decomposition with adaptive noise (CEEMDAN) decomposition and sensitive intrinsic mode function (IMF) selection was proposed. In this paper, the CEEMDAN algorithm was first applied to complete decomposition of arc current in series faults. Then, 12 feature indicators of arc current were defined, and the frequency band division of IMF component was realized according to the kurtosis index and energy feature which were more sensitive. On this basis, a feature calculation method based on time window was proposed to obtain the local features of the time scale of each high-frequency IMF component. Accurate selection of sensitive IMF components was realized by comparing feature indexes such as variance and root mean square value. Finally, for the current feature set, the second dimension reduction was realized by principal component analysis, and the series fault arc detection was implemented based on SVM. The feasibility of the proposed method and the validity of fault arc detection were proved by practical experiments.

Keywords: arc detection; CEEMDAN decomposition; frequency division; sensitive IMF selection; time window feature calculation; SVM

0 引言

低压配电网中,因触头接触不良、线路绝缘损坏而产生的电弧为故障电弧,电弧故障发生时,如若不及时采取可靠的检测和保护措施,则可能诱发电气火灾事故^[1-2]。按照发生位置不同,电弧故障分为串联电弧、并联电弧和接地电弧故障。对并联电弧和接地电弧故障来说,现有过流检测方法已能实现较为可靠的检测保护。串联电弧故障发生时,由于电弧阻抗等同于电路中串接的时变电阻,使回路故障电流要低于正常工作电流,致使过流保护装置无法对此类故障进行检测^[3]。从波形特征来看,各种非线性负荷的存在,使得串联电弧故障电流难以与负荷电流进行区分。因此,串联电弧检测方法的研究成为电弧检测技术研究领域的难点和热点^[4-6]。

希尔伯特黄变换(Hilbert Huang transform, HHT)因其良好的非线性、非平稳信号处理能力,在故障电弧检测中得到了广泛应用^[7-8]。HHT的核心是利用经验模态分解(empirical mode decomposition, EMD)将复杂信号自适应分解为多尺度本征模态函数(intrinsic mode function, IMF)^[9]。2003年, Wu等^[10]针对EMD算法的模态混叠问题,提出了集成经验模态分解(ensemble empirical mode decomposition, EEMD)算法,通过将频率均匀分布的高斯白噪声引入待分解信号,克服了信号间歇问题,避免了模态混叠。但由于白噪声干扰,易导致重构信号失真。2011年, Torres等^[11]提出自适应噪声的完备经验模态分解(complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN),进一步提升了分解信号的精确度和完备性,且大大降低了计算复杂度,该方法在电弧电流信号分析中尚未得到应用。

CEEMDAN算法虽实现了信号的完备分解,但是在故障电弧检测中,通常只有极少数IMF分量对故障电弧敏感而反映故障电弧的特征,其他多数IMF分量均为无效成分,甚至包含了干扰信息,而干扰特征易影响故障电弧的检测准确度。因此,设计一种有效IMF分量的选取策略,对于提高故障判别的准确度和检测效率至关重要。雷亚国^[12]提出一种基于相似性评估的敏感IMF分量选择方法,增强了潜在故障成分、削弱了故障无关的正常信息,并在机械故障信号分析中得以应用。张丽萍等^[13]提出一种基于方差贡献率的主要IMF分量选取方法,有效消除了噪声分量和虚假分量干扰,有利于改善串联故障电弧的检测效果。上述IMF分量的选择算法实现了多个主要IMF分量的粗选,仅在一定程度削弱了干扰信息、提升了检测效果,并未实现最强区分性的敏感IMF分量的精确选取。

因此,本文提出一种基于CEEMDAN分解与敏感

IMF分量精选的串联电弧故障检测方法。首先,采用CEEMDAN算法对电流信号进行分解,获取完备的IMF分量。然后,针对不同频率IMF分量,提出一种敏感IMF的精确选择策略。该策略首先以峭度指标和能量特征为判定依据,确定基频边界,实现频段划分;其次针对粗选出的高频段IMF,提出一种基于时间窗的局部特征提取方法,以基频IMF周期数为划分依据,将高频段各IMF划分为不交叠的时间窗,并计算各区段的特征指标;然后基于方差、均方根幅值等统计指标自适应的确定出判别力最强的IMF分量。最后,针对最强判别力IMF分量构建特征向量,采用主成分分析和支持向量机实现电流特征降维和故障检测。实验证明了本文所提CEEMDAN分解与敏感IMF分量精选方法在电弧故障电流零休、高次谐波、电流突变和尖峰脉冲等特征提取中的有效性和可行性,为实现串联电弧故障检测提供了新的技术思路。

1 CEEMDAN 分解

模态混叠是指分解所得单一IMF分量中包含完全不同频率的多个成分,或同一频率成分被分解到不同IMF分量中的现象。模态混叠产生的根本原因是信号间歇问题,因此,EEMD算法通过在待分解信号中引入均匀分布高斯白噪声,使信号在不同尺度上变为连续,缓解了模态混叠问题。但EEMD算法无法完全消除所引入的噪声干扰,使重构信号失真。CEEMDAN算法在对信号进行EMD分解的各阶段,通过自适应调整噪声系数,产生不同信噪比的高斯噪声并引入待分解信号,在避免模态混叠的同时,能消除虚假信息干扰。

假设原始待分解信号为 $x(t)$,则经过自适应添加高斯白噪声,并执行EMD分解直至残差分量不能继续分解为止。此时,可得CEEMDAN的所有 K 个IMF分量,则原始信号被分解后可表示为剩余残差 $R(t)$ 与各IMF分量 $IMF(t)$ 的叠加:

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

2 电流特征指标计算

借鉴机械故障诊断常用的特征计算方法^[14-15],本文定义了9个统计特征指标,以及能量特征、熵特征和能量熵特征,构成12维的电流特征向量,为故障电弧检测提供判定依据。假设CEEMDAN分解获得 K 个IMF分量,每个分量序列包含 N 个采样点,即 x_1, x_2, \dots, x_N ,则12个特征指标定义如下:

1) 均值特征:

$$\bar{X} = \frac{1}{N} \sum_{i=1}^N x_i \quad (2)$$

2) 方差特征:

$$\sigma^2 = \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{X})^2 \quad (3)$$

3) 均方根值:

$$X_{RMS} = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i)^2} \quad (4)$$

4) 方根幅值:

$$X_r = \left(\frac{1}{N} \sum_{i=1}^N |x_i| \right)^2 \quad (5)$$

5) 平均幅值:

$$\bar{X}_a = \frac{1}{N} \sum_{i=1}^N |x_i| \quad (6)$$

6) 峰值:

$$X_p = \max(|x_i|) \quad (7)$$

7) 峭度:

$$K = \frac{1}{N-1} \sum_{i=1}^N \frac{(x_i - \bar{X})^4}{\sigma^4} \quad (8)$$

8) 峭度指标:

$$K_f = \frac{K}{X_{RMS}^4} \quad (9)$$

9) 裕度指标:

$$L_f = \frac{X_p}{X_r} \quad (10)$$

10) 能量特征:

$$E = \sum_{i=1}^N (x_i)^2 \quad (11)$$

11) 熵特征:

$$H = - \sum_{i=1}^N P(x_i) \lg P(x_i) \quad (12)$$

式中: $P(\cdot)$ 代表概率。

12) 能量熵特征:

$$H_{EN} = - \sum_{i=1}^N P_i \lg P_i \quad (13)$$

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。

经上述运算,每个包含 N 个采样点的 IMF 分量被转换为一个 12 维的特征向量,该向量反映了信号序列的整体状态。

3 敏感 IMF 分量选取及串联电弧故障检测

3.1 基频分量确定与频段划分

本文定义的 12 个特征指标体现了不同频率 IMF 分量各自的特点,其中峭度指标和能量特征对于电流信号波动具有较强的敏感性。因此,本文以这两个指标为判定依据,对各 IMF 分量进行频段划分。当峭度指标取最小值、能量特征取最大值时对应的 IMF 分量波动幅度最

小、所含信息成分最多。因此,该频率分量对应于电弧电流信号中的基频成分。以基频 IMF 分量作为划分边界,高于该频率的 IMF 分量为高频段信号,低于该频率的 IMF 分量为低频段信号。

由于引起故障电弧的电流通常为高频信号,因此,频段划分后,只需针对高频段信号进行特征值计算和特征提取。这不仅能够降低特征值计算、特征提取和故障检测的复杂度,同时可以避免低频信号干扰,提升电弧故障检测的效率和准确率。

3.2 分区段局部特征计算与敏感 IMF 精确选取

当 IMF 分量的全部采样数据都参与指标计算时,所得特征能够反映信号的整体变化,在宏观上形成了 IMF 分量信号频段划分的重要依据。在高频分量区间,部分频率相近 IMF 分量的特征指标变化趋势具有相似性,区分故障电流信号的关键特征容易被淹没。因此,本文从特征指标需要充分体现电弧电流信号局部变化的微观角度出发,提出一种基于时间窗的特征指标计算方法,并基于高频 IMF 的分区段特征指标实现最敏感 IMF 分量的准确选取。

所提算法步骤如下:

1) 分析确定 IMF 基频分量的周期数 M ;

2) 依据周期数,将所有高频 IMF 分量沿时间维度划分为 M 个不交叠区段,形成时间窗,即 $IMF_1^i, IMF_2^i, \dots, IMF_M^i$, 其中 i 表示第 i 个 IMF 分量。

3) 针对第 i 个 IMF 分量的 M 个时间窗,参照第 2 节定义计算 12 个特征值,则第 j 个时间窗形成特征 $F_j^i = [\bar{X}, \sigma^2, X_{RMS}, X_r, \bar{X}_a, X_p, K, K_f, L_f, E, H, H_{EN}]$ 。因此,第 i 个 IMF 分量形成的特征向量为 $M \times 12$ 维,即 $F^i = [F_1^i, F_2^i, \dots, F_M^i]$ 。

4) 选取 IMF 分量中各时间窗的方差 σ^2 、均方根值 X_{RMS} 、方根幅值 X_r 、平均幅值 \bar{X}_a 、能量特征 E 和能量熵特征 H_{EN} 作为判断指标。

如果前后时间窗(如第 j 和 $j+1$ 窗口)的上述判断指标值波动小于等于阈值 θ ,说明该 IMF 分量中各时间窗信号平稳,表明其中不包含引起故障的电流信息;

如果前后时间窗的判断指标值均发生了明显跃变,且跃变幅度大于阈值 θ ,表明该 IMF 分量中前后时间窗信号不平稳,说明其中包含了引起故障的电流信息。

5) 经过上述计算和比较,从前后时间窗特征指标值跃变超出阈值 θ 的各 IMF 分量中选出跃变幅度最大的分量,作为串联故障电弧检测中的敏感 IMF 成分,该分量具有最强的判别力。

基于时间窗的特征计算能捕获具有周期性的局部特征,更加细致地表达了信号在时间维度的变化,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。基于此,精选出的敏感 IMF 分量能更好地刻画和描述信号的关键特征,提升故障电弧检测的准确度。

3.3 串联故障电弧检测

电流信号经 CEEMDAN 分解、频段划分和敏感 IMF 分量选取,获得了判别性最强的 IMF 分量特征信息,其特征维度为 $M \times 12$ 。为了更好地实现故障电弧检测,本文对采集所得电流数据的特征集合采用主成分分析算法^[16-17]执行了二次特征提取,进一步降低特征维数、保留有效特征,以改善故障电弧检测的效率和准确度。

支持向量机(support vector machine, SVM)^[18-19]是一种经典的结构风险最小化学习方法,该算法以训练误差为优化约束条件,以置信范围值最小为优化目标。SVM 在解决小样本、非线性及高维模式识别问题中表现出特有的优势,能够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,非常适合处理二分类问题,在故障检测中应用广泛。因此,本文选取 SVM 作为串联故障电弧的检测器。

4 试验分析

4.1 电弧电流信号采集

本文搭建的串联故障电弧发生电路原理如图 1 所示,电路输入电压 220 V,使用带宽 200 kHz 带铁芯线圈的低功率电流互感器(LPCT)进行电流数据采集^[20]。

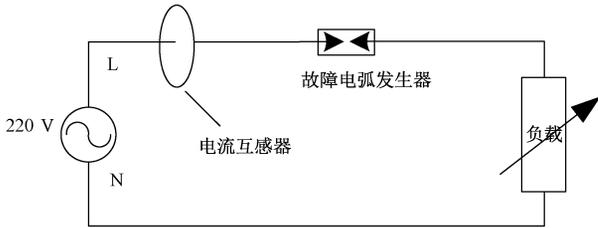


图 1 串联故障电弧发生电路原理图

Fig. 1 Schematic circuit diagram of series fault arc occurrence

实验平台如图 2 所示,实验中采用的故障电弧发生器由直径为 10.0 mm 铜电极作为动触头,直径 8.0 mm 石墨电极作为参考静触头。初始状态下,动触头与静触头紧密接触,电路无故障电弧发生。试验中,调节动触头远离静触头,则两电极产生间隔,形成串联故障电弧。

考虑到线性和非线性负载对故障电弧电流的不同影响,分别采用了电炉负载(线性)、电脑负载和微波炉负载(非线性)进行实验。每种负载下,采集了 10 组正常电流数据和 30 组串联电弧发生时的故障电流数据,构建电流数据集。

4.2 电流数据集构建

基于图 2 所示故障电弧发生采集平台,通过示波器



图 2 串联故障电弧发生平台

Fig. 2 Series fault arc generating platform

记录了故障电弧发生前后电路电流的波形图像和相关数据。电弧电流数据采集,示波器采样率设置为 50 kSa/s,信号采样时长为 20 ms。电流数据集简况如表 1 所示。不同负载的电弧电流波形如图 3 所示。

表 1 不同负载下的电流数据集简况

Table 1 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

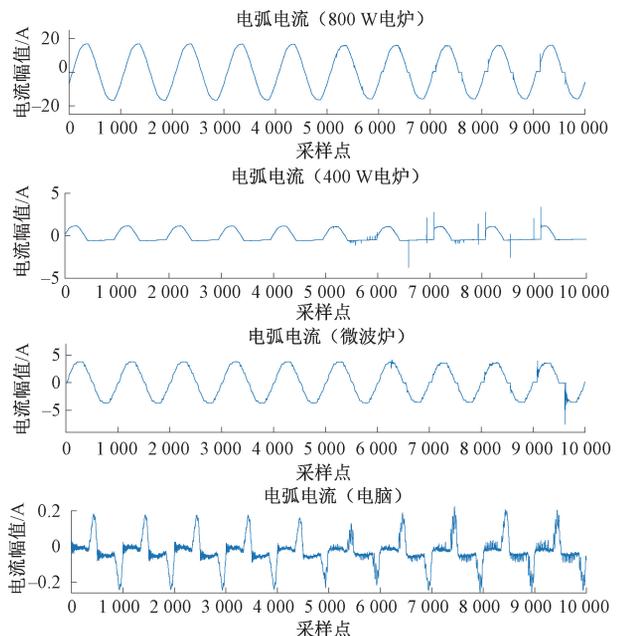


图 3 不同负载下故障电弧电流波形

Fig. 3 Fault arc current waveforms under different loads

训练数据集: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 组数据作为训练样本,用于实现特征指标计算和 SVM 训练。

测试数据集:4 种负载下剩余的 5 组正常电流和 10 组故障电弧电流,共 60 组数据用作测试样本。

为保证获取检测效果可靠,实验中通过 10 次交叉试验,获得平均准确度作为所提算法的性能评价。

4.3 故障电弧电流信号的分解试验

本文采用 CEEMDAN 算法对电弧电流信号进行了分解,结果如图 4 所示。图 4(a) 为微波炉负载的电流波形,其中前 5 个周波是未发生故障电弧的正常电流波形,后 5 个周波为发生故障电弧后的电流波形。故障电弧发生后,电流信号呈现明显的幅值降低、零休和高频噪声干扰。

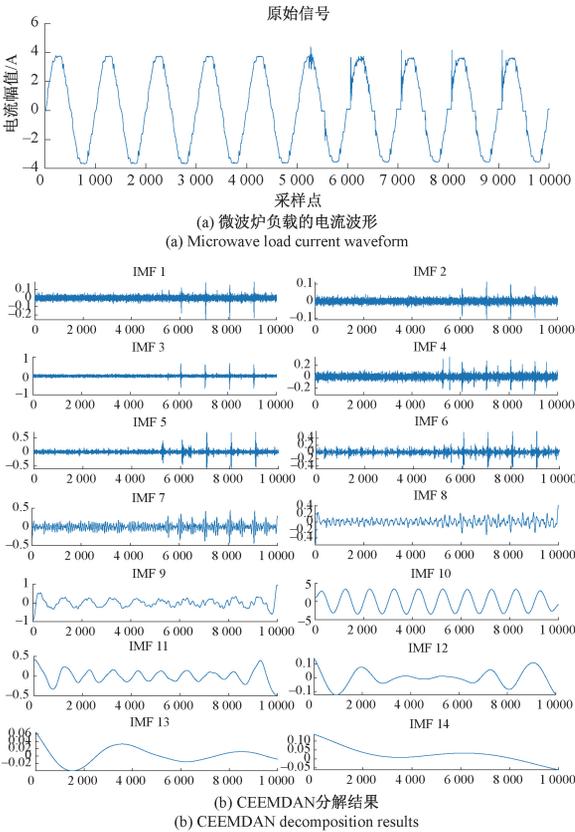


图 4 微波炉负载的电流波形及分解结果展示

Fig. 4 Display of fault arc current and decomposition results under microwave load

实验表明,CEEMDAN 算法将微波炉负载下电流信号自适应的分解为 14 个分量,实现了电弧电流信号在不同频率范围内细致且完备的分解,能有效克服 EMD 分解算法的混叠问题。观察图 4(b) 分解结果,分量 IMF10 包含 10 个周期,且为完整正弦信号,其频率与原始电流信号一致,因此,IMF10 对应基频分量。以 IMF10 分量为边

界,IMF1~IMF9 可划归为高频段信号,IMF11~IMF14 可划归为低频段信号。显然,各频率成分划分简洁清晰,表明信号分解完备性较好,无模态混叠出现。另外,在 CEEMDAN 分解中,分量 IMF4~IMF7 的波形在电弧发生前后存在显著差异,特别是 IMF4 和 IMF5 具有良好的区分度,对于故障电弧检测贡献度较大。

实验发现,针对 4 种不同负载的电流数据,通过 CEEMDAN 分解均能获得 12~16 个不同频率的 IMF 分量,且其中均包含有高频分量、基频分量和低频分量。这表明 CEEMDAN 信号分解的完备性较好,在克服模态混叠和端点效应中具有显著优势,且分解所得分量信号的判别力较强。因此,本文选取 CEEMDAN 算法用于电弧电流信号分解是可行的。

4.4 故障电弧电流特征计算与敏感 IMF 选取

为了更好地对各 IMF 分量做数学描述,同时降低故障检测运算的复杂度,本文采用了均值、方差等统计特征指标,以及能量特征、熵特征和能量熵特征,共 12 个特征值作为各 IMF 分量的特征描述。针对图 4(b) 中的分解结果,计算了 14 个 IMF 分量的特征,如表 2 所示。因此,采集获得的每组电流信号可用 14×12 维的特征矩阵表达。

表 2 不同 IMF 分量的特征值计算结果

Table 2 Calculation results of eigenvalues of different IMF components

IMF 名称	均值	方差	均方根值	方根幅值	平均幅值	峰值
IMF1	-1.03×10^{-4}	4.75×10^{-4}	0.021 8	2.48×10^{-4}	0.015 7	0.303 8
IMF2	-1.61×10^{-4}	1.41×10^{-4}	0.011 9	7.45×10^{-5}	0.008 8	0.123 5
IMF3	2.37×10^{-5}	0.002 7	0.051 7	0.001 0	0.0316	0.714 5
IMF4	1.02×10^{-4}	0.001 6	0.040 5	8.39×10^{-4}	0.029 0	0.323 5
IMF5	1.37×10^{-4}	0.004 7	0.068 2	0.001 7	0.040 8	0.667 3
IMF6	-3.57×10^{-4}	0.006 5	0.080 3	0.002 8	0.052 8	0.612 4
IMF7	2.58×10^{-4}	0.009 0	0.095 0	0.005 0	0.070 4	0.445 0
IMF8	-2.21×10^{-4}	0.008 4	0.091 8	0.004 6	0.068 2	0.540 3
IMF9	0.001 2	0.057 2	0.239 1	0.036 9	0.192 0	1.037 9
IMF10	0.012 9	5.101 8	2.258 8	4.106 3	2.206 4	3.561 7
IMF11	-0.003 4	0.030 0	0.173 1	0.016 5	0.128 6	0.548 7
IMF12	9.22×10^{-4}	0.004 3	0.065 3	0.002 4	0.048 8	0.200 4
IMF13	0.003 4	0.001 7	0.041 5	0.001 2	0.034 2	0.091 7
IMF14	0.016 0	0.004 8	0.071 1	0.002 7	0.052 0	0.221 2

IMF 名称	峭度	峭度指标	裕度指标	能量特征	熵特征	能量熵特征
IMF1	19.44 1	8.6×10^7	1.23×10^3	4.754	1.099	0.000 841
IMF2	11.857	5.99×10^8	1.59×10^3	1.407	1.211	0.000 28
IMF3	45.485	6.37×10^6	713.93	26.72	0.731	0.003 76
IMF4	10.377	3.85×10^6	385.19	16.408	1.516	0.002 63
IMF5	27.132	1.25×10^6	401.82	46.523	1.046	0.006 26
IMF6	13.898	3.34×10^5	219.92	64.537	1.438	0.008 28
IMF7	5.347	6.57×10^4	89.717	90.227	2.199	0.010 71
IMF8	6.987	9.85×10^4	116.22	84.25	1.954	0.009 86
IMF9	4.039	1.243×10^3	28.16	571.788	2.336	0.049 06
IMF10	1.539	0.059 1	0.867 4	5.102×10^4	3.264	0.025 17
IMF11	3.99	4.44×10^3	33.18	299.706	2.796	0.035 12
IMF12	3.847	2.11×10^5	84.24	42.66	2.691	0.005 41
IMF13	2.323	7.82×10^5	78.51	17.23	3.104	0.000 95
IMF14	4.501 2	1.76×10^5	81.89	50.51	2.548	0.003 36

表 2 数据显示,12 个特征指标体现了多尺度 IMF 分量的不同特点,其中峭度指标和能量特征具有较强的区分度。因此,通过对比各 IMF 分量的峭度指标和能量特征,能清晰的判断出 IMF10 为基频分量,可作为频段划分的边界。其中,IMF1~IMF9 对应高频段信号,IMF11~IMF14 为低频段分量。该结论与 4.3 节直接观察图 4(b) 所得结果完全相同。证明本文提出的频段划分策略是有效的。

本文实验采集的电流信号均包含 10 个周期,因此根据提出的时间窗特征计算方法,高频段各 IMF 分量均可划分为 10 个窗口。然后,针对每个时间窗分别计算均值、方差等 12 个特征指标。表 3 展示了 IMF5 分量中 10 个时间窗特征值的计算结果。

表 3 IMF5 分量的不同时间窗特征值计算结果

Table 3 Calculation results of the segment eigenvalues of IMF5 component

时间窗	均值	方差	均方根值	方根幅值	平均幅值	峰值
窗 1	-5.959×10^{-4}	0.001 4	0.037 2	0.000 84	0.029	0.143 3
窗 2	-1.487×10^{-4}	0.001 7	0.041 6	0.001 1	0.033	0.115 5
窗 3	1.984×10^{-4}	0.001 5	0.039 0	0.000 97	0.031 2	0.136 3
窗 4	3.049×10^{-4}	0.001 7	0.041 6	0.001 1	0.033 5	0.136 7
窗 5	3.525×10^{-4}	0.001 4	0.038 1	0.000 92	0.030 3	0.115 7
窗 6	9.08×10^{-4}	0.004 6	0.068 1	0.002 1	0.047 5	0.393 9
窗 7	1.984×10^{-4}	0.007 9	0.086 6	0.003 1	0.055 6	0.483 6
窗 8	-2.203×10^{-6}	0.009 0	0.094 7	0.002 5	0.050 3	0.661 3
窗 9	5.453×10^{-6}	0.008 5	0.092 4	0.002 4	0.049 3	0.667 3
窗 10	1.469×10^{-4}	0.008 7	0.093 3	0.002 5	0.049 9	0.650 8

时间窗	峭度	峭度指标	裕度指标	能量特征	熵特征	能量熵特征
窗 1	3.127	1.795×10^6	170.022	1.382	2.616	0.104 5
窗 2	2.839	0.951×10^6	136.19	1.728	2.951	0.122 3
窗 3	2.989	1.292×10^6	140.39	1.521	2.721	0.111 8
窗 4	2.967 3	0.991×10^6	121.95	1.730 6	2.767	0.122 4
窗 5	2.900 8	1.38×10^6	125.75	1.450 1	2.792	0.108 1
窗 6	9.207 1	3.821×10^5	166.12	4.634	1.868	0.259 7
窗 7	11.549	1.873×10^5	156.64	7.851	1.815	0.300 3
窗 8	21.454	2.66×10^5	261.49	8.974	1.277	0.317 4
窗 9	22.105	3.03×10^5	274.82	8.541	1.208	0.312 0
窗 10	21.142	1.783×10^5	261.49	8.709	1.195	0.312 6

表 3 数据中,通过比较方差、均方根值、方根幅值、平均幅值、能量特征和能量熵特征等指标发现,前 5 个周期的指标值与后 5 个周期的指标值存在显著差异。表明该 IMF 分量中存在引起故障电弧的相关信息,因此该分量可以作为敏感 IMF 分量的备选项之一。

为了准确选取最敏感的 IMF 分量,实验中分别计算了 IMF1 至 IMF9 等 9 个高频分量的分区段特征指标。综合比较所有特征值发现,IMF4 分量前 5 周期和后 5 周期的特征值变化幅度最大,显著性最强,因此,选取 IMF4 分量作为最终选定的敏感量。其他各 IMF 分量前 5 周期和后 5 周期的特征值也具有一定变化,但变化幅度低于

IMF4,区分度不明显。因此,按照区分度显著,且跃变幅度最大的原则,选定 IMF4 分量为最敏感分量。

综合上述分析,本文准确选取了最有效的敏感 IMF 分量,然后采用 10 个时间窗,每个窗口 12 个特征值对故障电弧电流信号进行特征描述。因此,每组电流信号(含 10 000 个采样点)最终被转换为一个 120 维的特征向量。4 种负载类型下的正常电流和故障电弧电流信号共包含 160 组电流数据,经过时间窗特征提取,最终形成规模为 160×120 的电流特征库。

4.5 基于 SVM 的故障电弧检测试验

尽管经过 IMF 分量选取,在一定程度上降低了无效信息干扰,但针对每个敏感分量提取的 120 维特征中仍然包含较多的冗余信息和干扰信息,这些信息增加了电弧故障检测的复杂度,而且容易影响检测准确度。因此,本文在采用 SVM 做故障电弧检测前,基于主成分分析算法对构建的电流特征集合执行了二次特征提取,用于挖掘更有效的电流关键特征。

串联电弧检测属于典型的二分类问题,因此,实验中采用了 SVM 作为故障检测器,其核函数采用了高斯核。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取值,实验结果如图 5 所示。其中最终确定的 SVM 惩罚因子取值为 10,核函数参数取值为 0.55。

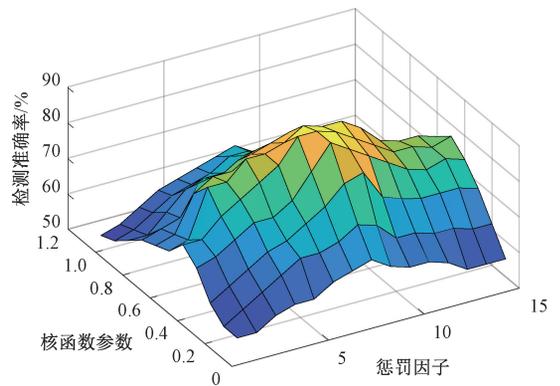


图 5 SVM 最优参数的确定试验

Fig. 5 Determination of optimal parameters of SVM

另外,主成分分析算法的主要影响因素为特征提取过程中最终保留的特征维数 d ,本文通过比较实验,确定了最佳的特征保留维数。图 6 展示了 10 次交叉实验中主成分分析特征维数对检测准确率的影响。

实验数据显示,10 次交叉实验中,尽管每次的训练样本不同,但主成分分析受到特征维数变化影响时,电弧电流检测准确率具有相似的变化趋势。当维数介于 0~20 时,检测准确率普遍较低,该阶段随着特征维数增加,特征中包含的有效信息逐步增多,因此检测准确率上升

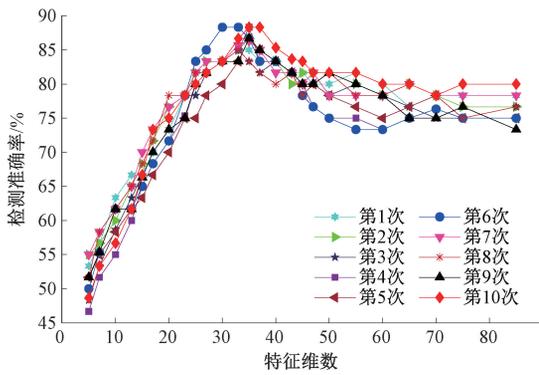


图6 主成分分析特征维数对检测准确率的影响

Fig. 6 The influence of feature dimensions of principal component analysis on detection accuracy

速度较快。当特征增加到 20 时,平均检测准确率达到 73.5%。当特征维数达到 25~40 维时,总体检测准确率较高,但受特征有效性和交叉实验样本不同的影响,检测准确率存在小幅波动,整体都在 80% 以上。当特征维数继续增加超过 40 维时,保留特征中掺杂了冗余和干扰信息,导致检测准确率呈现一定幅度下降,但下降速率比较平缓,检测准确率基本维持在 75%~80% 之间。

通过交叉验证实验最终确定主成分分析算法的最优特征保留维数为 35,此时采用 SVM 得到的最优检测准确率为 88.33%,平均检测准确度达到 85.27%。

5 结论

为实现可靠的串联故障电弧检测,提出一种融合 CEEMDAN 分解与敏感 IMF 精选的串联电弧故障检测方法。基于 CEEMDAN 算法实现电弧电流分解,提出一种频段划分策略,实现高频段信号初选;提出一种敏感 IMF 分量的精确选取策略,确定了最有效的 IMF 分量,消除了无效 IMF 分量干扰,并降低了故障检测的复杂度。提出一种时间窗特征计算方法,实现了敏感 IMF 分量的局部特征提取,增强了电弧电流特征的对比如和判别力。采用主成分分析进一步消除冗余信息干扰,基于 SVM 实现串联故障电弧检测。本研究为故障电弧检测装置研发提供了一种有效的新思路。

特别致谢:本论文受湖北省电力有限公司科技项目(52153220001V)资助。

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): 321-329.
LIU G G, DU S H, SU J, et al. Research on LV arc fault protection and its development trends [J]. Power System Technology, 2017 41(1): 321-329.

[2] 刘艳丽,郭凤仪,朱连勇,等. 矿用电连接器串联型故障电弧诊断方法研究[J]. 电子测量与仪器学报, 2017, 31(8): 1257-1264.
LIU Y L, GUO F Y, ZHU L Y, et al. Study of diagnostic method on series fault arc of mining electric connector [J]. Journal of Electronic Measurement and Instrumentation, 2017, 31(8): 1257-1264.

[3] 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 K, ZHANG R CH, YANG J H, 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.

[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): 212-221.
LU Q W, WANG T, LI Z R, 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): 212-221.

[5] 余琼芳,胡亚倩,杨艺. 基于小波特征及深度学习的故障电弧检测[J]. 电子测量与仪器学报, 2020, 34(3): 100-108.
YU Q F, HU Y Q, YANF Y. Arc fault detection based on wavelet feature and deep learning [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(3): 100-108.

[6] 王毅,陈进,李松浓,等. 基于时频域分析和随机森林的故障电弧检测[J]. 电子测量与仪器学报, 2021, 35(5): 62-68.
WANG Y, CHEN J, LI S N, et al. Arc fault detection based on time and frequency analysis and random forest [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(5): 62-68.

[7] HUNG N E, SHEN Z, LONG S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear non-stationary time series analysis [J]. Proceedings of the Royal Society, 1998, 454: 903-995.

[8] 汪洋堃,张峰,张士文,等. 基于 HHT 的低压交流故障电弧检测方法研究[J]. 电器与能效管理技术, 2015(21): 1-7, 17.
WANG Y K, ZHANG F, ZHANG SH W, et al. Research of HHT based identification method for low voltage arc fault [J]. Electrical & Energy Management Technology, 2015(21): 1-7, 17.

[9] 郭凤仪,刘大卫,王智勇,等. 光伏系统直流故障电弧实验研究[J]. 电子测量与仪器学报, 2018, 32(6):

- 25-32.
GUO F Y, LIU D W, WANG ZH Y, et al. Experimental research on DC arc fault in PV system [J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(6):25-32.
- [10] WU Z H, HUNG N E. Ensemble empirical mode decomposition: A noise-assisted data analysis method [J]. Advances in Adaptive Data Analysis, 2009,1(1):1-41.
- [11] TORRES M E, COLOMINAS M A, SCHLOTTHAUER G, et al. A complete ensemble empirical mode decomposition with adaptive noise [C]. IEEE International Conference on Acoustics, Speech and Signal Processing, IEEE, 2011: 4144-4147.
- [12] 雷亚国. 基于改进 Hilbert-Huang 变换的机械故障诊断[J]. 机械工程学报, 2011, 47(5):71-77.
LEI Y G. Machinery fault diagnosis based on improved Hilbert-Huang transform [J]. Journal of Mechanical Engineering, 2011, 47(5):71-77.
- [13] 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.
ZHANG L P, MIAO X R, SHI D Y. Research on low voltage arc fault recognition method based on EMD and ELM [J]. Electric Machines and Control, 2016, 20(9):54-60.
- [14] 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 ZH Q, LIN Y D. Fault diagnosis of rolling bearing based on improved LMD and comprehensive characteristic index [J]. Journal of Hefei University of Technology: Natural Science, 2021, 44(2):145-150.
- [15] 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 L L, TAN H CH, LI X J, 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.
- [16] KEMPFERT K C, WANG Y S, CHEN C X, 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.
- [17] GUO F, GAO H, WANG Z, et al. Detection and line selection of series arc fault in multi-load circuit [J]. IEEE Transactions on Plasma Science, 2019, 47(11):5089-5098.
- [18] MIAO W, XU Q, LAM K H, et al. DC arc fault detection based on empirical mode decomposition of arc signatures and support vector machine [J]. IEEE Sensors Journal, 2021, 21(5):7024-7033.
- [19] GAO H, WANG Z, TANG A, et al. Research on series arc fault detection and phase selection feature extraction method [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70:1-8.
- [20] BAO G, GAO X, JIANG R, et al. A novel differential high-frequency current transformer sensor for series arc fault detection [J]. Sensors, 2019, 19(17):3649.

作者简介



宿磊, 2011 年于南加州大学获得硕士学位, 现在为国网湖北省电力有限公司电力科学研究院高级工程师, 主要研究方向为智能配电网与故障检测。

E-mail: sulei@me.com

Su Lei received his M. Sc. degree from the University of Southern California in 2011. Now he is a senior engineer at the Electric Power Research Institute of State Grid Hubei Electric Power Co., Ltd. His main research interests include smart distribution network and fault detection.



邹国锋(通信作者), 2013 年于哈尔滨工程大学获得博士学位, 现为山东理工大学电气与电子工程学院副教授, 主要研究方向: 智能信息处理, 复杂系统健康检测与诊断技术。

E-mail: zgf841122@163.com

Zou Guofeng (Corresponding author) received a Ph. D. degree from Harbin Engineering University in 2013. Now he is an associate professor in School of Electrical and Electronic Engineering of Shandong University of Technology. His main research interests include intelligent information processing, complex system health detection and diagnosis technology.