

DOI: 10.13382/j.jemi.B2104018

基于多维度特征提取的电弧故障检测方法^{*}

杨 洋¹ 黄罗杰¹ 李 平¹ 沈力峰¹ 吕 忠² 阳世群²
(1. 西南石油大学 计算机科学学院 成都 610500; 2. 应急管理部四川消防研究所 成都 610036)

摘 要:针对当前含多种电气故障的复杂电路电弧故障识别率低、训练速度慢的问题,提出一种窗口划分结合小波分解与经验模态分解(empirical mode decomposition,EMD)分别从时域、频域及时间尺度等多个维度提取电流特征量,利用机器学习分类模型进行电弧故障识别的方法。首先,利用搭建的电气故障实验平台采集故障及正常电流数据,并将电流数据进行窗口分段,然后分别使用小波变换与 EMD 方法对电流信号进行分解并计算不同维度上的特征量,将该特征信息作为分类算法的输入进行电弧故障诊断。经实验验证,该特征提取方法在梯度提升决策树(gradient boosting decision tree,GBDT)上的电弧故障检测准确率高达 98%,相比电流不分段的方式分类准确率提升了 1.87%,能有效获取电弧故障特征,实现对电弧故障高效率与高准确率检测。

关键词: 电弧故障;窗口划分;小波分解;经验模态分解;机器学习
中图分类号: TN911.71;TM501.2 **文献标识码:** A **国家标准学科分类代码:** 510.40

Arc fault detection based on multi-dimension feature extraction

Yang Yang¹ Huang Luojie¹ Li Ping¹ Shen Lifeng¹ Lv Zhong² Yang Shiqun²
(1. School of Computer Science, Southwest Petroleum University, Chengdu 610500, China;
2. Sichuan Fire Research Institute of MEM, Chengdu 610036, China)

Abstract: Aiming at the problem of low accuracy and slow training speed in complex circuits with multiple electrical faults, a method of window division combined with wavelet decomposition and empirical mode decomposition (EMD) is proposed to extract current characteristic quantities respectively from multiple dimensions in time domain, frequency domain and time scale, identifying arc fault by using machine learning classification models. Firstly, the fault and normal current data are collected by the electrical fault experimental platform, and the current data is segmented by window. Then, the wavelet transforming and EMD methods are used to decompose the current signal and calculate the characteristic quantities in different dimensions. The characteristic information collected is used as the input of the classification algorithm for arc fault diagnosis. The experimental results show that the arc fault detection accuracy of the feature extraction method on the gradient boosting decision tree (GBDT) is as high as 98%, which is 1.87% higher than that of the current without segmentation. It can effectively obtain the arc fault characteristics and realize the detection of arc fault with high efficiency and high accuracy.

Keywords: arc fault; window division; wavelet decomposition; EMD; machine learning

0 引 言

造成电气火灾的主要因素是线路故障、电气设备故障,而电弧故障常常是引发线路故障的直接原因。电弧

可以分为好弧和故障电弧,其中好弧指的是正常操作开关产生的电弧,如插拔插头、开关用电设备的时候产生的瞬时光弧,持续时间短,不会对线路和用电设备造成影响。包裹线路的绝缘层会由于线路长时间处于工作状态或超负荷工作状态下,出现老化、破损的现象,造成绝缘

性能下降,当电压达到一定值过后会引起电弧故障。故障电弧具有高温的特点,持续燃弧可能会引燃线路,进而导致火灾的发生。

目前电弧故障检测方法可分为两大类:1)构建多种电流电压阈值指标^[1];2)对电弧故障电流进行建模。阈值法主要是通过电流形态上的差异,即判断正常电流与故障电流序列之间的差异,将其与阈值做比较来判断是否发生电弧故障,文献[2]通过计算零休时间比例系数、滤波后的归一化相关系数来与经验阈值比较,从而识别出串联故障电弧,该方法虽实时性强,但泛化性较低。直接对电流信号建模是现在比较常用的手段,文献[3]采用3种不同的系数作为组合特征量来训练一个多层神经网络,特征量包含傅里叶系数、小波特征、梅尔频率倒谱数据^[4],采用深度学习方法的缺点是需要大量标注数据、训练时间较长,针对电弧故障检测任务实用性不强。文献[5-9]利用小波分析算法来进行电弧故障检测,小波分析被认为是傅里叶发展史上里程碑式的突破,被称为“数学显微镜”^[10],它能够同时提取时域和频域的信息,从而能够较精确地捕捉到数据的瞬时特征。经验模态分解(EMD)在信号处理方面运用较多,能够将原始的非平稳信号分解为多个本征模态函数(IMF)与一个残余项之和^[11-13]。近期结合小波分析与EMD来实现电弧故障检测的工作参考文献[14],利用EMD去分解小波去噪后的电流信号,提取单一的能量熵作为特征量,不能全方面捕获电弧电流的特征。此外,去噪会造成电流损失一部分本身的信息,这对于电弧故障检测是不利的。

针对以上问题,本文提出电流信号窗口分段结合小波分解与EMD共同提取原始电流信号特征的方法加快特征构造速度,增加数据量,有效解决含有多种电气故障的复杂电路电弧故障识别率低的问题。利用组合的特征向量来训练机器学习分类模型并完成模型效果评估。

1 数据采集与预处理

实验数据通过图1所示的电流数据采集平台获取,该平台主要由电弧故障发生器、电流互感器、示波器、开关、负载组成,其中电弧故障发生器有3种不同类型。

1.1 电弧故障实验平台搭建及数据采集

利用电流数据采集平台收集4种不同的实验数据:接触不良、炭化路径放电、相间高阻抗与正常电流波形,前3种故障数据对应的电弧故障发生器分别如图2(a)~(c)所示,其中相间高阻抗故障发生器不需要接负载,利用浸有盐溶液的滤纸采集相间高阻抗电弧故障电流波形。电流互感器将电流信号变比按100:1转换为小电流信号,采用TeKtronix型号为TBS1064的示波器来观察并收集电流信号。实验选择多种常见的家用电器如空

调、电脑、电水壶、电暖炉、微波炉、电饭煲、吹风机等,其中包含线性负载和非线性负载。




图1 电流数据采集平台

Fig. 1 Current data acquisition platform




图2 电弧故障发生器

Fig. 2 Arc fault generator

图2(a)接触不良故障发生器中主要包含步进电机、电极、可相对滑动的碳圆棒与紫铜锥棒。紫铜锥棒固定在底座上,通过步进电机来带动碳圆棒的前后移动,实现碳棒与铜棒点面式接触。为了高效利用实验装置,图2(b)炭化路径放电故障发生器是在接触不良故障发生器并联一个带破口导线的绝缘木板^[15],在破口处倒适量炭粉,电路接通市电220V的瞬间会发生强烈的炭化路径放电现象,在放电处会留下明显的熔痕。图2(c)相

间高阻抗放电故障发生器中包含一面开口的木箱和两条互不接触的两相导线,在两条导线上放置浸润了盐溶液的滤纸或棉纤维,接通电路便能产生明显的电弧。

1.2 数据预处理

图 3 和 4 所示分别是实测线性负载和非线性负载的正常电流、接触不良故障、炭化路径放电故障电流波形,图 5 所示是相间高阻抗故障波形,利用两种不同浓度的盐溶液浸润滤纸片,进行相间高阻抗故障数据采集。




图 3 线性负载的正常与故障电流波形

Fig. 3 Normal and fault current waveform of linear loads

由图 3、4 对比可看出,故障波形有明显的“平肩部”特征且接触不良故障电流振幅较大,能在短时间内达到电流峰值。采用窗口划分的方式对电流信号进行预处理,能够降低特征向量对噪声点的敏感度^[16],提高抗干扰能力,突出信号的局部特征。实验采集到的每一个电流波形总长度为 2 500 个数据点,窗口大小为超参数,实验选择窗口大小为 600。将每个电流信号按照时间顺序划分为 4 个长度均为窗口大小的子段,图 6 所示是电流信号分段示意图。

图 6 横坐标表示电流信号数据点数,纵坐标表示电流幅值。将所有划分后的电流信号作为原始数据样本集用来训练机器学习分类模型,并对分类效果进行测试评估。

2 电弧故障特征提取

考虑到电弧故障数据的多样性,只提取电流信号单一的特征量无法实现对含有多种电气故障电路的准确诊断,因此需要综合利用小波分析与经验模态分解方法,提




图 4 非线性负载的正常与故障电流波形

Fig. 4 Normal and fault current waveform of nonlinear loads




图 5 相间高阻抗故障电流波形

Fig. 5 Fault current waveform of interphase high impedance




图 6 信号分段示意图

Fig. 6 Diagram of signal segmentation

取电流信号不同维度的特征量。基于小波分解提取电流信号的方差、归一化能量变比和能量熵,基于 EMD 提取电流信号的能量熵。特征融合后训练分类模型,从而实现电弧故障检测。对于不同的负载,在不同的工作状态下,其波形特征也会发生变化,因此多维度提取电流信号的特征量,能够提高分类准确率。

2.1 小波分解提取特征量

电弧故障信号是随机发生,属于快速阶跃信号^[17]。小波分解法能够通过固定窗口面积来改变时间窗和频率窗的大小,在低频区域具有较高的频域分辨率和较低的时域分辨率,在高频区域具有较低的频域分辨率和较高的时域分辨率^[18],对信号具有较强的自适应性。

小波分解的实质是利用小波基经过平移和缩放将原始信号分解为一系列小波之和,公式如下:

$$WT(a, \tau) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} x(t) \cdot \psi\left(\frac{t - \tau}{a}\right) dt, a > 0 \quad (1)$$

式中: $x(t)$ 表示原始电流信号; ψ 为小波基函数; a 为尺度因子,控制小波基函数的伸缩; τ 为时移因子,用来控制小波基函数的平移。选择 Daubechies 作为小波基函数,具有正交性好、紧支、对不规则信号敏感等优点,缩写为 dbN, N 是小波基函数的阶数,实验选取 $N=2$, 并进行 5 层分解。图 7 所示是小波分解信号的示意图,原始信号 $x(t)$ 可以表示为:

$$x(t) = cA_1 + cD_1 = cA_2 + cD_2 + cD_1 = cA_3 + cD_3 + cD_2 + cD_1 = \dots \quad (2)$$

式中: cA_k 表示低频小波系数; cD_k 表示高频小波系数。电流信号被逐层分解,分解层数 k 越少,则分析速度越快,但频段分辨率较低。当分解的层数越多时,虽然分析速度较慢,但频段的分辨率较高,小波基在时域上的支撑长度也较长。




图 7 小波分解示意图

Fig. 7 Schematic diagram of wavelet decomposition

利用小波系数提取电弧故障电流信号的故障特征信息^[19]。通过计算标准差、归一化能量变比和能量熵 3 个特征量作为分析依据。

1) 标准差

标准差能够反映出一个数据集中随机变量之间的离散程度,计算公式如下:

$$\sigma(\text{coef}) = \sqrt{\frac{1}{n} \sum_{i=1}^n [\text{coef}(i) - \overline{\text{coef}}]^2} \quad (3)$$

$$\overline{\text{coef}} = \frac{1}{n} \sum_{i=1}^n \text{coef}(i) \quad (4)$$

式中: coef 表示小波系数; $\overline{\text{coef}}$ 表示小波系数的均值; n 为小波系数的点数,窗口划分之后的 $n = 600$ 。最终标准差特征向量 S 为:

$$S = [S(cA_k), S(cD_k), \dots, S(cD_3), S(cD_2), S(cD_1)] \quad (5)$$

2) 归一化能量变比

归一化能量变比 $P(\text{coef})$ 计算公式为:

$$P(\text{coef}) = \frac{E(\text{coef})}{E_{\text{total}}} \quad (6)$$

得到归一化能量变比特征向量 P 为:

$$P = [P(cA_k), P(cD_k), \dots, P(cD_3), P(cD_2), P(cD_1)] \quad (7)$$

3) 能量熵

小波分解提取能量熵 Ent_w 的计算公式为:

$$Ent_w = - \sum_{j=1}^{k+1} \{P_j(\text{coef}) \cdot \log[P_j(\text{coef})]\} \quad (8)$$

2.2 经验模态分解提取特征量

小波分解的不足之处是需要设定一个最优小波基函数,而经验模态分解是一种分析非线性或非平稳的时间序列数据的方法^[20],不需要设定基函数,具有较强的自适应性。EMD 过程是通过一种固定模式将输入信号分解为不同尺度的振荡分量 IMF 和一个残差趋势分量,其中 IMF 需要满足如下两个条件:1) IMF 过零点的个数和局部极值点数必须相等或者最多相差一次;2) IMF 的“局部平均值”为 0。

为了构造上(下)包络线,局部极大值(极小值)通过平滑插值(通常是三次样条差值法)来连接起来,上包络与下包络的平均值叫做信号的“局部平均值”^[21-22]。

EMD 分解电流信号的过程如下^[23]。

1) 找到电流信号中所有的极大值点和极小值点,通过极值点与插值法拟合电流信号上包络线 $e_1(t)$ 和下包络线 $e_2(t)$, 计算包络平均值 $\bar{e}(t) = \frac{e_1(t) + e_2(t)}{2}$ 。

2) 判断 $x(t) - \bar{e}(t)$ 的差值 $h(t)$ 是否满足 IMF 条件,若不满足,则令 $x(t) = h(t)$, 重复迭代直至满足 IMF 条件。若满足,则记 $c(t) = h(t)$ 为 $x(t)$ 的本征模态函数,将 $c(t)$ 从 $x(t)$ 中抽取出来,余下的部分信号 $r(t) = x(t) - c(t)$ 作为下一轮分解的原始序列。

3) 重复步骤 1)、2) 进行多轮分解,每一轮分解都能得到本征模态函数 $c_1(t), c_2(t), \dots, c_m(t)$ 和余项 $r(t)$ 。当 $r(t)$ 为一个单调函数时则停止分解过程,分解后的原始电流信号表示形式为:

$$x(t) = \sum_{i=1}^m c_i(t) + r(t) \quad (9)$$

利用 EMD 得到的 m 个 IMF 分量来计算能量熵 Ent_E , 计算过程与小波能量熵 Ent_w 类似。

2.3 特征构造

利用小波分解与 EMD 将每一个信号分解为一个 14 维的特征向量。分解单个电流信号得到一个特征向量的示意图如图 8 所示,不同颜色表示不同的特征量。收集所有信号分解之后得到的特征向量,得到一个特征矩阵,即特征向量集。




图 8 特征构造示意图
Fig. 8 Diagram of feature construction

图 8 中,由上至下的第一个黑色虚线框表示电流信号分解过程。第 2 个虚线框表示特征向量拼接过程,蓝色、黄色、粉色、灰色分别对应标准差 S 、归一化能量比 P 、小波能量熵 Ent_w 、EMD 能量熵 Ent_E 特征向量。最外面的黑色实线框表示分解单条电流信号的整个特征构造过程。

3 实验结果与分析

电弧故障检测算法流程框架图如图 9 所示,主要含数据采集与预处理、特征提取、故障分类与模型评估 3 个部分,依次对应图 9 中的虚线框部分。黑色实线框表示基于多维度特征提取的电弧故障检测方法的整体框架。算法的整个流程为利用电流数据采集平台收集 4 种电流数据并采用窗口划分方法将电流分为 4 段。然后利用小波分解与 EMD 方法分解电流信号,计算不同的特征量构造特征向量集。最后利用划分好的训练集与测试集分别进行模型训练和效果评估。实验结果中的加粗数字表示是评估指标分数最高的,分数越高表示效果越好。评估指标选择评价二分类模型性能的常用指标,评估指标关系参数说明如表 1 所示。

表 1 评估指标关系参数说明

真实标签	预测结果为正例	预测结果为反例
正例	真阳性 (TP)	假阴性 (FN)
反例	假阳性 (FP)	真阴性 (TN)

3.1 评估指标选择

电弧故障检测是一个二分类问题,样本被分为正类和负类两种,将正常电流数据的真实标签设置为 +1,故障电流数据的真实标签设置为 -1,那么模型预测的类别结果与真实标签之间的组合方式有 4 种关系,TP、FP、FN、TN。实验所用到的评估指标有准确率 (accuracy)、精确率 (precision)、召回率 (recall) 和 F1-score,取值均在 $[0, 1]$,值越大表示模型分类效果越好。

Accuracy 表示预测正确的结果占总样本的百分比,公式如下:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$
 (10)

Precision 表示对正样本结果中的预测准确程度,公式如下:

$$Precision = \frac{TP}{TP + FP}$$
 (11)

Recall 表示实际为正的样本中被预测为正样本的概率,公式如下:

$$Recall = \frac{TP}{TP + FN}$$
 (12)

F1-score 是基于召回率和精确率综合进行计算的一个评估指标,可看作一种加权平均^[24],计算公式为:

$$F1 - score = \frac{2 \cdot Precision \cdot Recall}{Precision + Recall}$$
 (13)

3.2 实验结果与分析

将收集到的特征向量矩阵利用不同的机器学习分类模型进行预测,其中训练数据 2 636 条,测试数据 1 026 条。表 2 是不同分类模型进行电弧故障检测的实验结果对比,可以看到集成学习模型 GBDT 和决策树识别电弧故障的能力较强。决策树是一个树形结构的机器学习算法,能够递归地选择最优特征,对输入数据进行逐层划分,从而得到预测结果,易于理解与实现。GBDT 是一种以决策树为基学习器的有监督集成学习算法,树与树间可实现并行化计算。

从表 2 各个模型平均训练时长来看,训练神经网络花费的时间约是训练 GBDT 的 2 倍。从整体效果来看,相比于 GBDT,决策树能够在相对较短的时间内完成模型训练且得到较好结果。

从表 3 可以对比看出同时利用小波分解与 EMD 方法进行电弧故障电流信号特征提取是最有效的,在每个分类模型上都有最好的分类结果。而只使用 EMD 方法进行电弧故障检测的分类准确率明显低于其他 2 种对比

方法,说明从不同维度提取电流信号的不同特征能够全方位获取故障电流的特征信息,进而有效提高电弧故障检测准确率。




图 9 电弧故障检测方法框架图

Fig. 9 Arc fault detection algorithm block diagram

表 2 不同分类模型测试结果对比

Table 2 Test results of different classifiers

分类模型名称	预测状态	Accuracy/%	Precision/%	Recall/%	F1-score/%	训练时长/s
GBDT	正常	98.54	96.98	100	98.46	8.575
	故障		100	97.25	98.60	
决策树	正常	97.95	95.82	100	97.86	0.026
	故障		100	96.15	98.04	
支持向量机	正常	71.05	70.63	65.49	67.96	0.169
	故障		71.38	75.96	73.60	
逻辑回归	正常	67.74	69.74	55.09	61.56	0.401
	故障		66.56	78.90	72.21	
神经网络	正常	91.23	86.54	96.26	91.14	16.812
	故障		96.33	86.79	91.31	

3.3 消融实验

为了验证小波分解与经验模态分解方法共同提取特征量的必要性,以及窗口分段的有效性,设计了两个消融

实验。第 1 个消融实验中对对比设置 3 种不同的特征构造方法,以分类 Accuracy 作为评估指标,实验结果如表 3 所示。

表 3 分类模型在不同特征构造方法下的准确率对比

Table 3 Accuracy of classifiers under different feature construction methods							(%)
特征构造方法	特征维度	GBDT	决策树	支持向量机	逻辑回归	神经网络	
只使用 EMD	1	82.85	87.62	53.61	53.02	53.41	
只使用小波分解	13	98.34	97.76	67.06	67.15	90.64	
小波分解+EMD	14	98.54	97.95	71.05	67.64	91.03	

此外,提取出特征对于分类模型决策树的重要性,特征重要性排名如图 10 所示,S 和 P 分别指的是小波系数提取的标准差与归一化能量比,下划线后面的数字表示特征向量的对应维度。Ent_E 和 Ent_W 分别指 EMD 能量熵、小波能量熵。

从图 10 可以看出,小波分解提取的特征量和 EMD 提取的特征量对实验结果都有较大影响,且 EMD 能量熵 Ent_E 的重要性分数为 0.151,总体排名第 4,远大于小波能量熵 Ent_W 的重要性分数 0.033,说明 EMD 提取的特

征能量熵在整个特征向量中具有重要作用。

结合表 3 与图 10 来看,说明同时利用小波分解与 EMD 进行电弧故障电流信号特征提取是有效的。

表 2 中 5 个分类模型的 ROC 曲线对比如图 11 所示,横坐标是假阳性率,纵坐标是真阳性率,对角虚线是参考线。图例由上至下分别代表 GBDT、决策树、神经网络、支持向量机、逻辑回归分类模型,“area”表示曲线下方的面积(AUC)。从图 11 可以看出,GBDT 与决策树的 AUC 较大,均大于 0.98,AUC 越接近于 1,说明电弧故障识别能力越好。




图 10 特征重要性排名
Fig. 10 Ranking of feature importance




图 11 ROC 曲线
Fig. 11 Diagram of ROC curves

第 2 个消融实验结果如表 4 所示,即数据预处理方法对比实验的结果,利用 GBDT 分类,对比两种数据预处理方法为窗口分段和不分段。窗口分段之后的总数据量增加 2.6 倍,特征构造所花费的总时长缩短 2 倍,其预测准确率提高 1.87%,这说明采用窗口分段的形式对电流信号进行预处理有积极效果,不仅缩短特征构造时间,还能增加数据量,提高分类准确率。

表 4 数据预处理方法对比实验

Table 4 Comparisons of data preprocessing methods			
数据预处理方法	特征收集总时长/s	数据量/条	Accuracy/%
不分段	767	1 390	96.67
窗口分段	355	3 662	98.54(↑1.87)

4 结 论

利用设计的电流数据采集平台,针对 3 种不同的电弧发生器采集接触不良故障、炭化路径放电故障和相间高阻抗故障电流,本文提出一种基于窗口划分并同时利用小波分解与经验模态分解识别电弧故障的方法,提取不同维度的特征量来充分捕获电流数据的特征。对比不同的机器学习分类模型,其中 GBDT 与决策树进行电弧

故障识别的准确率高达 98%。通过消融实验以及决策树模型中特征重要性排序,证明电弧故障检测同时使用小波分解与 EMD 两种方法的有效性,证明窗口分段的有益性。该特征提取方法能够高效判断出电弧故障,为电弧故障检测提供了新的思路。

参考文献

[1] 刘建伟. 故障电弧特征提取和自适应检测技术研究[D]. 杭州:浙江大学,2019.
LIU J W. Research on fault arc feature extraction and adaptive detection technology [D]. Hangzhou: Zhejiang University, 2019.

[2] 赵怀军,秦海燕,刘凯,等. 基于相关理论及零休特征融合的串联故障电弧检测方法[J]. 仪器仪表学报, 2020,41(4):218-228.
ZHAO H J, QIN H Y, LIU K, et al. Detection method of series fault arc based on correlation theory and zero-break feature fusion [J]. Chinese Journal of Scientific Instrument, 2020,41(4):218-228.

[3] 龙官微,穆海宝,张大宁,等. 基于多特征融合神经网络的串联电弧故障识别技术[J]. 高电压技术, 2021, 47(2):463-471.
LONG G W, MU H B, ZHANG D N, et al. Series arc fault identification technology based on multi-feature fusion neural network [J]. High Voltage Technology, 2021, 47(2):463-471.

[4] 余琼芳,胡亚倩,杨艺. 低压交流串联故障电弧检测概述[J]. 电器与能效管理技术, 2020(1):29-35.
YU Q F, HU Y Q, YANG Y. Overview of low voltage AC series fault arc detection [J]. Electrical Appliances & Energy Efficiency Management Technology, 2020(1): 29-35.

[5] 白辉,许志红. 基于小波包变换和高阶累积量的电弧故障识别方法[J]. 电力自动化设备, 2020,40(11): 195-202,224,203.
BAI H, XU Z H. Arc fault identification method based on wavelet packet transform and high-order cumulant [J]. Electric Power Automation Equipment, 2020, 40(11): 195-202,224,203.

[6] 陈瑞瑞. 基于小波变换的电弧故障检测技术研究[D]. 杭州:杭州电子科技大学,2013.
CHEN R R. Research on arc fault detection technology based on wavelet transform [D]. Hangzhou: Hangzhou Dianzi University, 2013.

[7] 刘晓明,赵洋,曹云东,等. 基于多特征融合的交流系统串联电弧故障诊断[J]. 电网技术, 2014, 38(3):795-801.
LIU X M, ZHAO Y, CAO Y D, et al. Serial arc fault diagnosis of AC system based on multi-feature fusion [J].

- Power System Technology, 2014, 38(3): 795-801.
- [8] 刘丽, 董文忠. 低压串联电弧故障特征与检测方法分析[J]. 电气开关, 2015, 53(3): 12-14.
- LIU L, DONG W ZH. Analysis of fault characteristics and detection method of low voltage series arc [J]. Electrical Switches, 2015, 53(3): 12-14.
- [9] 刘婷. 串联电弧故障检测方法研究及应用[D]. 沈阳: 沈阳工业大学, 2016.
- LIU T. Research and application of series arc fault detection method [D]. Shenyang: Shenyang University of Technology, 2016.
- [10] 辛元明, 谭峰, 田芳明. 基于小波变换的植物电信号降噪方法研究[J]. 电子测量与仪器学报, 2019, 33(12): 190-196.
- XIN Y M, TAN F, TIAN F M. Research on denoising method of plant electrical signal based on wavelet transform [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(12): 190-196.
- [11] 贺利芳, 曹莉, 张天骐. Levy 噪声中 EMD 降噪的随机共振研究[J]. 电子测量与仪器学报, 2017, 31(1): 21-28.
- HE L F, CAO L, ZHANG T Q. Stochastic resonance study of EMD denoising in levy noise [J]. Journal of Electronic Measurement and Instrumentation, 2017, 31(1): 21-28.
- [12] 戴邵武, 陈强强, 刘志豪, 等. 基于 EMD-LSTM 的时间序列预测方法[J]. 深圳大学学报(理工版), 2020, 161(3): 49-54.
- DAI SH W, CHEN Q Q, LIU ZH H, et al. Time series prediction method based on EMD-LSTM [J]. Journal of Shenzhen University (Science & Technology Edition), 2020, 161(3): 49-54.
- [13] 王志斌, 曹红伟, 刘佳佳. 基于小波包去噪与 EMD 的故障电弧检测算法研究[J]. 电测与仪表, 2018, 56(6): 117-121.
- WANG Z B, CAO H W, LIU J J. Research on fault arc detection algorithm based on wavelet packet denoising and EMD [J]. Electrical Measurement and Instrumentation, 2018, 56(6): 117-121.
- [14] 阳世群, 黄曜伟, 黄涵煜. 绝缘和木板形成炭化路径放电及火灾危险性[J]. 建设科技, 2017(5): 34-35.
- YANG SH Q, HUANG Y W, HUANG H Y. Carbonization path discharge and fire risk of insulation and wood [J]. Construction Science and Technology, 2017(5): 34-35.
- [15] 丁鑫, 竺红卫, 殷浩楠, 等. 基于机器学习方法的直流电弧故障检测[J]. 传感器与微系统, 2017, 36(11): 128-132.
- DING X, ZHU H W, YIN H N, et al. DC arc fault detection based on machine learning method [J]. Sensors and Microsystems, 2017, 36(11): 128-132.
- [16] 项新建, 林章, 周律. 基于小波变换的故障电弧检测方法研究[J]. 低压电器, 2013(6): 55-58.
- XIANG X J, LIN Z, ZHOU L. Research on fault arc detection method based on wavelet transform [J]. Low Voltage Appliance, 2013(6): 55-58.
- [17] 孙鹏, 郑志成, 高翔. 基于小波分析的故障电弧检测方法[J]. 高压电器, 2012, 48(1): 25-29, 34.
- SUN P, ZHENG ZH CH, GAO X. Fault arc detection method based on wavelet analysis [J]. High Voltage Appliances, 2012, 48(1): 25-29, 34.
- [18] 孙鹏, 董荣刚, 郑志成. 基于小波分析信号特征频段能量变比的故障电弧诊断技术研究[J]. 高压电器, 2010, 46(7): 50-54.
- SUN P, DONG R G, ZHENG ZH CH. Study on fault arc diagnosis technology based on wavelet analysis signal characteristic frequency band energy ratio [J]. High Voltage Appliances, 2010, 46(7): 50-54.
- [19] HUANG N E, SHEN Z, LONG S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[J]. Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences, 1998, 454(1971): 903-995.
- [20] 王婷. EMD 算法研究及其在信号去噪中的应用[D]. 哈尔滨: 哈尔滨工程大学, 2010.
- WANG T. Research on EMD algorithm and its application in signal denoising [D]. Harbin: Harbin Engineering University, 2010.
- [21] 刘剑生, 王细洋. 基于 EMD 与 BP 神经网络的齿轮故障诊断[J]. 失效分析与预防, 2020, 15(6): 370-375, 392.
- LIU J SH, WANG X Y. Fault diagnosis of gear based on EMD and BP neural network [J]. Failure Analysis and Prevention, 2020, 15(6): 370-375, 392.
- [22] 张之猛, 刘晨晨, 刘伯胜, 等. 经验模态分解中的包络线拟合算法仿真分析[J]. 系统仿真学报, 2009, 21(23): 7690-7693.
- ZHANG ZH M, LIU CH CH, LIU B SH, et al. Simulation and analysis of envelope fit algorithm in empirical mode decomposition [J]. Journal of System Simulation, 2009, 21(23): 7690-7693.
- [23] 刘金硕, 刘必为, 张密, 等. 基于 GBDT 的电力计量设备故障预测[J]. 计算机科学, 2019, 46(S1): 392-396.
- LIU J SH, LIU B W, ZHANG M, et al. Fault prediction

of power metering equipment based on GBDT [J]. Computer Science, 2019, 46(S1): 392-396.

- [24] 邓勇, 于晨松, 文浩. 基于倒谱和决策树的模拟电路故障诊断[J]. 电子测量与仪器学报, 2017, 31(3): 430-435.

DENG Y, YU CH SH, WEN H. Fault diagnosis of analog circuits based on cepstrum and decision tree [J]. Journal of Electronic Measurement and Instrumentation, 2017, 31(3): 430-435.

作者简介



杨洋, 2019 年获得西南石油大学学士学位, 现为西南石油大学软件工程硕士研究生, 主要研究方向为异常检测、序列挖掘。

E-mail: yeung2y@163.com

Yang Yang received her B. Sc. degree from Southwest Petroleum University in 2019.

Now she is a M. Sc. candidate at Southwest Petroleum University. Her main research interests include anomaly detection and sequence mining.



黄罗杰, 2018 年毕业于金陵科技学院, 现为西南石油大学硕士研究生, 研究方向为异常检测、图像处理。

E-mail: louis_luojie@163.com

Huang Luojie graduated from Jinling University of Science and Technology in 2018.

Now he is a M. Sc. candidate at Southwest Petroleum University. His main research interests include anomaly detection and image processing.



李平 (通信作者), 电子科技大学与德国波茨坦大学联合培养博士, 香港理工大学博士后, 现为西南石油大学教授, 研究方向为图机器学习、序列挖掘。

E-mail: pingkly@163.com

Li Ping (Corresponding author), jointly

trained by University of Electronic Science and Technology of China and University of Potsdam in Germany and worked at Hong Kong Polytechnic University as a postdoc. Now she is a professor at Southwest Petroleum University. Her main research interests include graph machine learning and sequence mining.



沈力峰, 2019 年获得西南石油大学学士学位, 现为西南石油大学网络空间安全硕士研究生, 主要研究方向为复杂网络、控制策略。

E-mail: 570276@qq.com

Shen Lifeng received his B. Sc. degree from Southwest Petroleum University in 2019. Now he is a M. Sc. candidate at Southwest Petroleum University. His main research interests include complex networks and control strategies.



吕忠, 2016 年获得西南交通大学电气工程硕士学位, 现为应急管理部四川消防研究所助理工程师, 主要研究方向为电气防火、火灾物证鉴定。

E-mail: 1028112291@qq.com

Lv Zhong received his M. Sc. degree from Southwest Jiaotong University in 2016. He is currently an assistant engineer at Sichuan Fire Research Institute of MEM. His main research interests include electrical fire prevention and fire evidence identification.



阳世群, 研究员, 现为应急管理部四川消防研究所火因中心主任, 主要研究方向为火灾原因调查、电气火灾防控。

E-mail: 984699728@qq.com

Yang Shiqun, researcher, director of Fire Cause Center of Sichuan Fire Research Institute, Ministry of Emergency Management. Her main research interests include fire cause investigation and electrical fire prevention and control.