

变频器负载回路串联故障电弧检测及选线方法*

蔡佳成 高洪鑫 王智勇 徐佳宁 彭继慎

(辽宁工程技术大学电气与控制工程学院 葫芦岛 125105)

摘要: 串联故障电弧的高温是引发电气火灾的主要原因之一,针对工业变频器负载回路中串联故障电弧尚无有效保护手段的问题,提出了一种新的串联故障电弧检测及选线方法。首先,针对工业领域常用的三相变频器负载回路开展了不同线路中发生串联故障电弧的实验;其次,利用基于能量收敛原则改进的变分模态分解将变频器前端A相电流信号自适应分解为多个模态分量,依次将单个模态分量乘以能量系数并重构,得到多个电流信号的特征增强信号,并建立特征矩阵;再次,对特征矩阵进行分块,利用核主成分分析对每块矩阵进行降维,并对降维信号组成的矩阵进行二次降维构建故障特征向量;最后,利用鸚鵡算法优化的支持向量机对串联故障电弧进行检测及选线。结果表明:该方法仅通过分析变频器前端A相电流可以实现变频器整个回路中6条线路的串联故障电弧检测及选线,检测及选线准确率均达到98%以上。

关键词: 故障电弧;故障检测及选线;变分模态分解;核主成分分析;支持向量机

中图分类号: TM501.2;TN98

文献标识码: A

国家标准学科分类代码: 510.40

Fault detection and line detection method of series arc fault in frequency converter load circuit

Cai Jiacheng Gao Hongxin Wang Zhiyong Xu Jianing Peng Jishen

(Faculty of Electrical and Control Engineering, Liaoning Technical University, Huludao 125105, China)

Abstract: The high temperature of series arc fault is one of the main causes of electrical fire. Aiming at the problem that there is no effective protection method for the series arc fault in the load circuit of industrial frequency converter, a new method of fault detection and line selection for the series arc fault was proposed. First, the series arc fault experiments in different lines were carried out for the load circuit of three-phase frequency converter commonly used in industrial field. Second, the improved variational mode decomposition based on the principle of energy convergence was used to adaptively decompose the A-phase current signal at the front end of the frequency converter into multiple modal components. After multiplying the single modal component by the energy coefficient, the feature enhancement signals of multiple current signals were reconstructed, and the feature matrix was established. Third, the feature matrix was divided into blocks, and the kernel principal component analysis was used to reduce the dimension of each block matrix, and the matrix composed of the reduced dimension signal was reduced twice to construct the fault feature vector. Finally, the support vector machine optimized by the pelican optimization algorithm was used to detect the series arc fault and select the fault line. The results show that the proposed method can realize the fault detection and line selection of the series arc fault in six lines of the whole circuit of the frequency converter only by analyzing the A-phase current signal at the front end of the frequency converter, and the accuracy of fault detection and line selection is more than 98%.

Keywords: arc fault; fault detection and line selection; variational mode decomposition; kernel principal component analysis; support vector machine

0 引言

工业领域中,三相电动机广泛应用于驱动各类机械设备,随着变频技术的不断发展,越来越多的三相电动机采用变频器进行驱动。但变频器控制的三相电动机回路中的电连接器和电缆,长期受电动机振动、拖拽等外力作用,且工作环境条件恶劣,时常会出现接触松动或锈蚀、线缆断裂等问题,造成接触不良、接触电阻增大,进而产生辉光放电或火花放电等物理现象;严重时将引发串联故障电弧,造成供电中断、设备损坏、电气火灾等安全事故。串联故障电弧具有高阻性,导致故障状态下回路电流低于正常工作电流,现有常规过流保护装置无法实现保护。因此,研究变频器负载回路中的串联故障电弧检测可为研制工业故障电弧断路器提供参考,对保障工业供电系统可靠性、预防电气火灾具有重要意义。

针对交流供电系统中的串联故障电弧研究工作主要集中在民用、航空和工业三相系统。基于分析电流或电压信号特征的串联故障电弧检测方法是目前的研究热点。

在民用领域的串联故障电弧检测方法的研究中,供电电源采用 AC 220 V/50 Hz,负载一般采用灯、吹风机、电磁炉、显示器、冰箱等。文献[1]提取电流平均值、谐波幅值、小波能量熵特征并融合,通过阈值实现串联故障电弧检测;文献[2]针对不同负载类型,利用序列浮动前向选择方法提取 3 组特征,通过 k 近邻实现串联故障电弧检测;文献[3]提取电流时域矩阵奇异值和频域赫斯特指数作为故障特征,通过 BP 神经网络实现串联故障电弧检测;文献[4-6]利用信号分解方法将电流信号分解为多个本征模函数(intrinsic mode function, IMF)并提取故障特征,分别通过支持向量机(support vector machine, SVM)、阈值法、概率神经网络实现串联故障电弧检测;文献[7-10]分别通过一维空洞卷积神经网络、一维卷积神经网络、自归一化卷积神经网络、具有注意力机制的深度残差收缩网络实现串联故障电弧检测;文献[11]利用电流互感器采集高频剩余磁通的耦合信号,通过短观测窗奇异值分解与重构实现串联故障电弧检测。

在航空领域的串联故障电弧检测方法的研究中,供电电源采用 AC 115 V/400 Hz,负载一般采用电阻、电感、自耦变压整流器等。文献[12]利用电流信号经验模态分解(empirical mode decomposition, EMD)的自回归模型参数作为故障特征,通过最小二乘支持向量机实现串联故障电弧检测;文献[13]计算电流信号的集合经验模态分解能量熵作为故障特征,通过 BP 神经网络实现故障电弧检测;文献[14]对电流信号进行广义 S 变换,提取 2 kHz 分量的均方根值和能量作为故障特征,通过 SVM

实现故障电弧检测;文献[15]提取电流信号的赫斯特指数、间谐波方差和小波能量熵作为故障特征,通过卷积神经网络结合长短期记忆神经网络实现故障电弧检测。

在工业领域的串联故障电弧检测方法的研究中,供电电源采用 AC 380 V/50 Hz,负载一般采用三相电动机和变频器。文献[16]设计了 5 个指数调制的高通滤波器,并提取电流信号的高频分量实现串联故障电弧检测;文献[17-19]分别利用电流信号的变分模态分解(variational mode decomposition, VMD)熵特征、经验小波变化奇异值特征、分数阶傅里叶变换奇异值特征,通过 SVM 实现串联故障电弧检测。

综上所述,国内外学者针对交流领域的串联故障电弧提出了大量的检测方法并证明了其有效性。但文献[1-15]的串联故障电弧检测方法是针对民用和航空领域,与工业领域的供电电压和典型负载存在较大差别,研究成果难以直接应用到工业领域。文献[16-19]提出检测方法虽然可以检测到工业领域的三相电动机和变频器回路中的串联故障电弧,但文献[16-18]尚未考虑变频器后端发生的串联故障电弧,文献[19]尚未开展变频器负载回路中的串联故障电弧选线的研究工作。

针对上述问题,提出采用变频器前端 A 相电流实现变频器负载回路中 6 条线路的串联故障电弧检测及选线思路,并提出一种新的串联故障电弧特征增强与检测方法。利用能量收敛原则改进的 VMD 自适应分解变频器前端 A 相电流信号,通过逐层乘以能量系数并重构对故障特征进行增强,以减弱串联故障电弧特征被工频分量淹没的问题;利用故障增强信号构建特征矩阵,通过矩阵分块与两次核主成分分析(kernel principal component analysis, KPCA)降维提取串联故障检测及选线特征,并利用鹈鹕算法(pelican optimization algorithm, POA)优化的 SVM 实现串联故障电弧的检测及选线。

1 串联故障电弧实验研究

1.1 实验平台

串联故障电弧实验平台如图 1 所示。实验平台主回路采用 AC 380 V/50 Hz 电源供电,实验负载采用 VFD110E43A 型变频器和 Y160M-6-11 kW 型三相异步电动机。串联故障电弧发生器的动、静触头分别采用直径为 5 mm 的尖头铜棒和平头碳棒;通过步进电机控制动触头与静触头分离产生串联故障电弧。实验过程中同步采集变频器前端 A 相电流,数据采集使用 LHB100A5VY2 型电流互感器、阿尔泰 USB3200 型数据采集卡和计算机,计算机通过 LabVIEW 软件编写的上位机程序实现数据存储,数据采样频率设置为 10 kHz。

利用搭建的实验平台开展不同负载电流、不同工作




图 1 实验平台
Fig. 1 Experimental platform

状态下的串联故障电弧实验。三相电动机运行过程中的电流主要是受拖动的负载转矩影响,实际工业现场中设备的负载转矩经常会发生变化或波动。因此,为了模拟实际运行情况,设置了上述 4 种负载电流条件,包括满载(20 A)、非满载(15 A、18 A)、负载波动(15~20 A 变化);其中负载电流通过调整三相电动机所带的摩擦负载来设置。工作状态分为正常状态和不同线路发生的串联故障电弧状态;正常状态是指线路正常工作,不设置故障电弧发生器;不同线路发生的串联故障电弧状态是指故障电弧发生器串联在变频器前端 A 相、前端 B 相、前端 C 相、后端 A 相、后端 B 相、后端 C 相,即图 1(a)中的线路 1~6 位置,并通过控制动、静触头分离产生串联故障电弧。

共计开展了 28 组实验,实验方案如表 1 所示。实验组别 1~4、5~8、9~12、13~16、17~20、21~24、25~28 分别是 4 种负载电流条件下对应的正常状态、前端 A 相故障、前端 B 相故障、前端 C 相故障、后端 A 相故障、后端 B 相故障、后端 C 相故障。

1.2 实验结果分析

实验采集的不同实验条件下的电流波形如图 2 所示。变频器负载为非线性负载,正常状态下的电流波形为双峰特性;变频器前端 A 相、前端 B 相、前端 C 相、后端 A 相中发生串联故障电弧时,变频器前端 A 相电流的尖峰或毛刺增多,且双峰幅值差发生变化;但在变频器后

端 B 相、后端 C 相中发生串联故障电弧时,变频器前端 A 相电流除电流幅值略微减小之外,其余特征并不明显。

表 1 实验方案
Table 1 Experimental scheme

实验组别	负载电流/A	工作状态
1~4	15、18、20、负载波动	正常状态
5~8	15、18、20、负载波动	前端 A 相故障
9~12	15、18、20、负载波动	前端 B 相故障
13~16	15、18、20、负载波动	前端 C 相故障
17~20	15、18、20、负载波动	后端 A 相故障
21~24	15、18、20、负载波动	后端 B 相故障
25~28	15、18、20、负载波动	后端 C 相故障




图 2 变频器前端 A 相电流波形
Fig. 2 Front end A-phase current waveform of frequency converter

为了通过分析变频器前端 A 相电流特征实现变频器回路的串联故障电弧检测及选线,有必要对变频器前端 A 相电流中的微弱特征进行特征增强与深入分析。

2 串联故障电弧检测及选线方法

2.1 方法总体思路

为了深入挖掘变频器前端 A 相电流中的故障特征,提出一种结合能量收敛的变分模态分解 (energy convergence variational mode decomposition, ECVMD)、故障特征增强、两级 KPCA 降维、POA-SVM 的串联故障电弧检测及选线方法,具体实现步骤如下:

步骤 1) 采集 2 个周波 (400 个采样点) 的变频器前端 A 相电流信号,利用有效值归一化后,采用 ECVMD 将电流信号自适应分解为 N 个模态分量;

步骤 2) 分别对每个模态分量乘以能量系数并重构,利用得到的 N 个特征增强信号构建故障特征矩阵;

步骤 3) 将特征矩阵划分为多块,利用 KPCA 将每块矩阵降维,再次利用 KPCA 将多个降维后信号组成的矩阵进行降维,并作为串联故障电弧检测及选线特征;

步骤 4) 利用 POA 对 SVM 参数进行寻优,建立基于 POA-SVM 的串联故障电弧检测及选线模型。

2.2 ECVMD 原理及分解结果

1) ECVMD 原理

VMD 是一种非递归信号分解方法,通过将信号分解问题转变为带有约束条件的变分问题,在约束条件内反复迭代寻找最优解,从而将非平稳信号分解成一系列不同中心频率的 IMF。当分解层数设置为 k 时,构造的约束变分模型为^[20]:

$$\min_{\{\beta_k\}, \{\omega_k\}} \sum_k \left\| \partial_t \left(\left(\delta(t) + \frac{z}{\pi t} \right) \cdot \beta_k(t) \right) \cdot e^{-j\omega_k t} \right\|^2 \quad (1)$$

$$\sum_k \beta_k(t) = f(t) \quad (2)$$

式中: z 为旋转因子, $\beta_k(t)$ 为信号分解得到的 IMF 分量, $f(t)$ 为原始信号, $\omega_k(t)$ 为中心频率, $\delta(t)$ 为单位脉冲函数。

引入二次惩罚因子 σ 和拉格朗日算子 Λ 将上式约束问题转换为非约束问题。得到的增广拉格朗日函数为:

$$\begin{aligned} L(\{\beta_k\}, \{\omega_k\}, \Lambda) = & \sigma \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) \cdot u_k(t) \right] e^{-j\omega_k t} \right\|^2 + \\ & \|f(t) - \sum_{k=1}^K \beta_k(t)\|^2 + \langle \Lambda(t), f(t) - \sum_{k=1}^K \beta_k(t) \rangle \end{aligned} \quad (3)$$

利用交替方向乘子法从两个方向交替更新 $\beta_k(t)$ 和 $\omega_k(t)$,得到式(1)中约束变分问题的最优解为:

$$\hat{\beta}_k^{n+1}(\omega) = \frac{\hat{f}(t) - \sum_{i \neq k} \hat{\beta}_i(\omega) + \hat{\Lambda}(\omega)/2}{1 + 2\sigma(\omega - \omega_k)^2} \quad (4)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{\beta}_k(\omega)| d\omega}{\int_0^\infty |\hat{\beta}_k(\omega)|^2 d\omega} \quad (5)$$

VMD 克服了 EMD 的模态混叠和端点效应问题,但需要设置分解层数 k 。 k 值设置太小,会造成欠分解,无法分离出有效的 IMF; k 值设置太大,会造成过分解,产生无用的 IMF。由于变频器负载正常工作电流波形成分复杂,在发生串联故障电弧时又会引入一定的随机性和不稳定性,且在不同位置发生串联故障电弧时的信号特征也存在差异。因此,每组电流信号的最优 VMD 层数并不是确定值。

为了解决不同电流信号下最优分解层数的确定问题,提出一种可以自适应确定分解层数的 ECVMD,实现原理如图 3 所示,具体实现步骤如下:

步骤 1) 设置 VMD 初始参数,初始分解层数设置为 2、二次惩罚因子设置为 500、迭代收敛容差设置为 1×10^{-1} 。

步骤 2) 对电流信号进行 VMD 分解,得到 k 个 IMF,计算第 k 个 IMF 的能量占比 E ,公式如式(6)所示。

$$E = \frac{\sum_{i=1}^{400} IMF_k(i)}{\sum_{i=1}^{400} s(i)} \quad (6)$$

式中: IMF_k 为第 k 个模态分量; s 为电流信号。

步骤 3) 当 E 大于能量收敛阈值 0.003 时,将分解层数加 1,重复步骤 2 操作;当 E 小于等于能量收敛阈值 0.003 时,则分解完成,输出 ECVMD 结果。




图 3 ECVMD 原理

Fig. 3 The principle of ECVMD

2) ECVMD 结果

由于 ECVMD 采用能量收敛原则确定最优分解层数,因此对不同电流数据的分解层数不是固定值;通过多组实验统计,实验中最优分解层数在 3~8 层之间。为了更好的对比不同线路发生串联故障电弧时 IMF 的变化情况,选取最优分解层数为 4 层的 4 组电流信号对应的 ECVMD 结果如图 4 所示;在后端 B 相、C 相发生串联故障电弧时,虽然电流信号中故障特征并不明显,但通过 ECVMD 后,在 $IMF_1 \sim IMF_4$ 中均存在了明显的故障特征。

2.3 故障特征增强方法与结果

1) 故障特征增强方法研究

自适应噪声的完备经验模态分解^[4]、小波包变换^[5]、经验小波变换^[6,18]、EMD^[12]、VMD^[17]等信号分解已经在故障电弧特征提取领域获得了重要应用,但目前方法大多数是采用分解方法将电流信号分解为多个 IMF,并分别提取每个 IMF 的故障特征,故障特征信息中缺乏各 IMF 之间的联系^[21]。为此,提出一种分别对每层信号乘以能量系数并重构的特征增强方法;设故障特征增强信号分别为 $ES_1 \sim ES_k$,则表达式为:

$$\begin{cases} ES_1 = \gamma \times \eta_1 \times IMF_1 + IMF_2 + \cdots + IMF_k \\ ES_2 = IMF_1 + \gamma \times \eta_2 \times IMF_2 + \cdots + IMF_k \\ \vdots \\ ES_k = IMF_1 + IMF_2 + \cdots + \gamma \times \eta_k \times IMF_k \end{cases} \quad (7)$$

$$\eta_j = \sqrt{\frac{1}{400} \sum_{i=1}^{400} s(i)^2} / \sqrt{\frac{1}{400} \sum_{i=1}^{400} IMF_j(i)^2} \quad (8)$$

式中: s 为原始电流信号; k 为 ECVMD 的层数; γ 为能量系数; $j=1,2,\dots,k$ 。

2) 故障特征增强结果

利用 2.3 节 1) 中的方法对图 4 中的 ECVMD 结果进行故障特征增强,其中能量系数 γ 设置为 0.7。故障特征增强结果如图 5 所示;在线路发生故障电弧时, $ES_1 \sim ES_4$ 均出现了明显的故障特征,且不同线路发生串联故障电弧时的故障特征也存在一定差异。

2.4 基于两级 KPCA 的故障特征提取方法

电流信号经过 ECVMD 和特征增强后变换为多维数据,且由于 ECVMD 对电流信号的分解层数是自适应的,造成数据维数并不固定。针对上述问题,提出一种两级 KPCA 降维的故障特征提取方法,使得在不同分解层数下的故障特征量均为 40 个。

1) KPCA 原理

KPCA^[22]是在主成分分析(principal component analysis, PCA)的基础上引入了核函数^[23],在特征空间中计算样本之间的协方差矩阵,并对该协方差矩阵进行特征值分解,得到主成分和对应的特征值,即为降维后数据。KPCA 能够有效地处理非线性数据,并保留更多的




图4 ECVMD 结果

Fig. 4 The results of ECVMD

数据特征。具体实现步骤如下:

步骤 1) 对于特征增强的样本集 $EIMF_1, EIMF_2, \dots, EIMF_k$, 通过映射 Φ 实现样本点到空间样本点的转换, 得到 $\Phi(ES_1), \Phi(ES_2), \dots, \Phi(ES_k)$, 上述过程需满足中心




图 5 故障特征增强结果

Fig. 5 The results of fault feature enhancement

化条件 $\sum_{j=1}^k \Phi(ES_j) = 0$ 。

步骤 2) 选择核函数, 计算核矩阵 $\mathbf{H}$, 计算公式如式 (9) 所示。

$$\mathbf{H}(ES_i, ES_j) = [b \cdot s(ES_i, ES_j) + c]^d \quad (9)$$

式中: b, c, d 为核函数参数。

步骤 3) 对核矩阵 $\mathbf{H}$ 进行中心化处理, 得到中心化核矩阵 $\mathbf{H}_c$, 公式如式 (10) 所示。

$$\mathbf{H}_c = \mathbf{H} - \mathbf{I}_N \mathbf{H} - \mathbf{H} \mathbf{I}_N + \mathbf{I}_N \mathbf{H} \mathbf{I}_N \quad (10)$$

式中: $\mathbf{I}_N$ 为 $N \times N$ 矩阵, 每个元素为 $1/N$ 。

步骤 4) 计算 $\mathbf{H}_c$ 的特征值 $\lambda_1, \lambda_2, \dots, \lambda_n$ 和对应的特征向量 $\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_n$, 将特征向量按降序排列。

在使用 KPCA 时, 常用的核函数有高斯核函数、多项式核函数、线性核函数、指数核函数和拉普拉斯核函数等, 文中选取的是高斯核函数。

2) 两级 KPCA 降维的故障特征提取原理

基于两级 KPCA 降维的故障特征提取方法的原理如图 6 所示。首先, 对故障特征增强信号组成的特征矩阵 $\mathbf{F}$ 分为 10 个 40×40 的分块矩阵, 分别为 $\mathbf{F}_1 \sim \mathbf{F}_{10}$; 然后, 利用 KPCA 分别将分块矩阵 $\mathbf{F}_1 \sim \mathbf{F}_{10}$ 降维为 40×1 的向量, 并按顺序放置在 40×10 的一级降维矩阵 $\mathbf{F}'$ 中; 最后, 再次利用 KPCA 将一级降维矩阵 $\mathbf{F}'$ 降维为 40×1 的向量, 该向量即为提取的故障电弧检测及选线特征。

2.5 故障识别模型与识别结果

1) POA-SVM 识别模型

SVM^[24] 是一种用于分类或预测的监督式学习方法, 主要通过构建最优超平面实现分类或回归任务, 并通过支持向量来确定超平面位置。SVM 不仅可以处理线性可分问题, 还可以通过核函数来解决非线性可分问题, 且该算法具有较好的泛化性和鲁棒性, 已经广泛应用于不同领域的的数据分类中。

利用径向基核函数的 SVM 建立识别模型, 用于串联故障电弧的检测及选线。在使用时, SVM 的惩罚因子 c 和核函数参数 g 对分类结果具有十分重要的影响, 为了获得更好的串联故障电弧检测及选线性能, 采用 POA 对参数 c 和 g 进行寻优。

POA^[25] 是一种模拟鸟类捕食行为的群智能优化算法, 灵感来源于鹈鹕捕食行为。鹈鹕在海面上巡逻时, 会依靠视觉和听觉感知猎物的位置, 并采用高速俯冲的方式捕获猎物; 在 POA 中, 将鹈鹕视为搜索空间中的一个个体, 而猎物则对应着目标函数的最优解。鹈鹕算法具有较好的全局搜索能力和收敛速度, 可以应用于多种优化问题。POA 主要通过探索、开发两个阶段实现位置更新, POA 优化 SVM 的流程如图 7 所示。其中 POA 的初始参数中, 种群大小设置为 20、最大迭代次数设置为 100。

2) 串联故障电弧检测及选线结果

为了测试提出串联故障电弧检测及选线方法的有效性, 在表 1 的 1~4 组中分别截取 700 段电流数据、在 5~28 组中分别截取 300 段电流数据, 共计得到 6 400 组电




图 6 基于两级 KPCA 降维的故障特征提取原理

Fig. 6 Fault feature extraction principle based on two-level KPCA dimensionality reduction




图 7 POA 优化 SVM 流程

Fig. 7 POA optimizes SVM process

后端C相故障	4	0	0	0	1	1	294
后端B相故障	0	0	0	0	1	297	2
后端A相故障	0	0	0	0	298	2	0
前端C相故障	2	0	0	297	0	0	1
前端B相故障	0	8	291	0	0	0	1
前端A相故障	3	292	4	0	0	0	1
正常	1392	3	2	0	1	0	2
正常	正常	前端A相故障	前端B相故障	前端C相故障	后端A相故障	后端B相故障	后端C相故障

图 8 串联故障电弧检测及选线结果

Fig. 8 The results of the fault detection and line selection for the series arc fault

3 与其他方法对比分析

3.1 不同分解方法对比分析

流数据,每段电流数据为 2 个周波。利用提出的方法分别提取 6 400 组电流数据的故障特征,正常状态、前端 A 相故障、前端 B 相故障、前端 C 相故障、后端 A 相故障、后端 B 相故障、后端 C 相故障对应故障特征向量的类别标签分别设置为 0、1、2、3、4、5、6;6 400 组故障特征样本平均分为训练样本和测试样本;利用训练样本建立 POA-SVM 识别模型,并将测试输入代入到训练好的模型,得到的串联故障电弧检测及选线结果如图 8 所示,统计得到串联故障电弧检测准确率为 99.31%、选线准确率为 98.78%。

为了测试 ECVMD 相比其他分解方法在 1.1 节实验条件下的优越性,将提出方法中的 ECVMD 分别替换为 EMD、固有时间尺度分解 (intrinsic time-scale decomposition, ITD)、傅里叶分解 (fourier decomposition method, FDM) 和 VMD;由于特征增强中的能量系数对检测和选线结果具有重要影响,因此对每种分解方法都测试了不同能量系数下的串联故障电弧检测准确率和选线准确率,分别如图 9、10 所示;其中 VMD 相比于 EMD、

ITD、FDM 3 种分解方法在 1.1 节实验条件下具有更高的检测及选线准确率,且通过能量收敛改进的 ECVMD 相比 VMD 的串联故障电弧检测和选线准确率都有了一定提升。同时,提出方法在能量系数设置为 0.7 时,串联故障电弧检测准确率和选线准确率最高,验证了能量系数选取的合理性。




图 9 5 种分解方法在不同能量系数下的串联故障电弧检测准确率
Fig. 9 The accuracy of the series arc fault detection under different energy coefficients by five decomposition methods




图 10 5 种分解方法在不同能量系数下的串联故障电弧选线准确率
Fig. 10 The accuracy of the series arc fault line selection under different energy coefficients by five decomposition methods

3.2 消融实验

为了测试提出方法中的特征增强环节的必要性,通过将 3.1 节中 5 种测试方法去掉特征增强环节开展了消融实验,测试结果如表 2 所示。在 1.1 节实验条件下,虽然 ITD、FDM、VMD、ECVMD 4 种方法在去掉特征增强环节后串联故障电弧检测准确率仍高于 90%,但故障选线准确率均低于 90%。通过对比图 9 和 10 可知,5 种分解方法在添加特征增强方法后的串联故障电弧检测准确率和选线准确率均出现了不同幅度的提升,验证了提出的特征增强方法的有效性和必要性。

表 2 消融实验测试结果

Table 2 The test results of ablation experiment (%)		
信号分解方法	故障电弧检测准确率	故障电弧选线准确率
EMD	82.72	62.47
ITD	94.63	85.31
FDM	96.22	89.53
VMD	96.59	83.69
提出方法	97.78	85.59

3.3 与现有串联故障电弧特征提取方法对比分析

为了验证提出方法在在 1.1 节实验条件下的优越性,分别利用 4 种串联故障领域现有的特征提取方法提取 2.5 节 2) 中截取数据的故障特征,并利用 POA-SVM 对串联故障电弧检测及选线准确率进行了测试。对比的方法如下:

1) 文献[26]利用 db3 小波基对电流信号进行 5 层分解,计算各细节信号的模极大值作为故障特征。

2) 文献[27]利用线性调频 Z 变换得到变频器前端电流信号 0~500 Hz 的频谱,提取两段电流低频频谱差值的平均值、2 次谐波变化率、4 次谐波变化率、6 次谐波变化率、频谱平均值、电流信号差值平均值构建特征向量。

3) 文献[19]对电流信号进行小波阈值降噪、分段线性拟合、一阶差分预处理,然后进行分数阶傅里叶变换,提取分数阶傅里叶变换幅值矩阵的奇异值作为故障特征。

4) 文献[18]利用经验小波变换对电流信号进行 5 层分解,建立各分解信号的改进吸引子轨迹矩阵,提取各矩阵的前 2 个奇异值作为故障特征。

不同特征提取方法在在 1.1 节实验条件下的串联故障电弧检测及选线准确率如表 3 所示,提出方法和文献[18]的串联故障电弧检测的准确率高于 90%;但文献[18]对串联故障电弧选线准确率不足 80%,无法对故障线路排查或维修提供有效参考。

表 3 不同特征提取方法的串联故障电弧检测及选线准确率
Table 3 The accuracy of the series arc fault detection and line selection using different feature extraction methods (%)

特征提取方法	串联故障电弧检测	串联故障电弧选线
	准确率	准确率
文献[26]	59.09	52.66
文献[27]	79.56	56.87
文献[19]	84.22	63.97
文献[18]	95.34	76.66
提出方法	99.31	98.78

4 结 论

针对变频器负载回路的串联故障电弧,研究了基于

A相电流的故障检测和选线方法。提出了一种基于能量收敛原则改进的VMD,通过能量收敛阈值确定信号的最优分解层数,实现电流信号的自适应分解,可为不同领域中的信号分析提供一种有效的分解方法;提出了一种逐层乘以能量系数的故障特征增强方法,结合信号分解类方法使用可以有效提高串联故障电弧检测及选线准确率,可为特征提取中的信号增强提供一种新的思路;提出一种两级KPCA降维特征与POA-SVM算法的串联故障电弧检测及选线方法,可以通过分析变频器前端A相电流实现变频器负载回路的串联故障电弧检测及选线,检测和选线准确率分别为99.31%、98.78%,可为研制低成本工业故障电弧断路器提供参考。

参考文献

- [1] 何志鹏,李伟林,邓云坤,等. 低压交流串联故障电弧辨识方法[J]. 电工技术学报, 2023, 38(10): 2806-2817.
HE ZH P, LI W L, DENG Y K, et al. The detection of series AC arc fault in low-voltage distribution system[J]. Transactions of China Electrotechnical Society, 2023, 38(10): 2806-2817.
- [2] ZHANG Y, CHEN H C, LI Z, et al. Lightweight AC arc fault detection method by integration of event-based load classification[J]. IEEE Transactions on Industrial Electronics, 2024, 71(4): 4130-4140.
- [3] 江军,李威,李波,等. 电流频谱Hurst指数在串联电弧故障检测中的应用[J]. 控制理论与应用, 2022, 39(3): 561-569.
JIANG J, LI W, LI B, et al. Application of hurst exponent of current spectrum in series arc fault detection[J]. Control Theory and Applications, 2022, 39(3): 561-569.
- [4] 宿磊,沈煜,杨帆,等. 融合CEEMDAN分解与敏感IMF精选的串联电弧故障检测[J]. 电子测量与仪器学报, 2022, 36(10): 173-180.
SU L, SHEN Y, YANG F, et al. Series arc fault detection combining CEEMDAN decomposition and sensitive IMF selection[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(10): 173-180.
- [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): 195-203.
BAI H, XU ZH H. Arc fault identification method based on wavelet packet transform and high-order cumulant[J]. Electric Power Automation Equipment, 2020, 40(11): 195-203.
- [6] 王毅,刘黎明,李松浓,等. 基于经验小波变换复合熵值与特征融合的故障电弧检测[J]. 电网技术, 2023, 47(5): 1912-1919.
WANG Y, LIU L M, LI S N, et al. Arc fault detection based on empirical wavelet transform composite entropy and feature fusion[J]. Power System Technology, 2023, 47(5): 1912-1919.
- [7] 蒋慧灵,白嘎力,周郑,等. 基于一维空洞卷积神经网络的故障电弧检测方法[J]. 清华大学学报(自然科学版), 2024, 64(3): 492-501.
JIANG H L, BAI G L, ZHOU ZH, et al. An arc fault detection method based on a one-dimensional dilated convolutional neural network[J]. Journal of Tsinghua University (Science and Technology), 2024, 64(3): 492-501.
- [8] WANG Y, HOU L M, PAUL K C, et al. ArcNet: Series AC arc fault detection based on raw current and convolutional neural network[J]. IEEE Transactions on Industrial Informatics, 2022, 18(1): 77-86.
- [9] 张婷,王海淇,张认成,等. 基于自归一化神经网络的电弧故障检测方法[J]. 仪器仪表学报, 2021, 42(3): 141-149.
ZHANG T, WANG H Q, ZHANG R CH, et al. An arc fault detection method based on the self-normalized convolutional neural network[J], Chinese Journal of Scientific Instrument, 2021, 42(3): 141-149.
- [10] 胡从强,曲娜,张帅,等. 连续小波变换和具有注意力机制的深度残差收缩网络在低压串联电弧故障检测中的应用[J]. 电网技术, 2023, 47(5): 1897-1905.
HU C Q, QU N, ZHANG SH, et al. Application of continuous wavelet transform and deep residual shrinkage network with attention mechanism in detection of low voltage series arc fault[J]. Power System Technology, 2023, 47(5): 1897-1905.
- [11] JIANG R, BAO G H, HONG Q T, et al. A coupling method for identifying arc faults based on short-observation-window SVDR[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-10.
- [12] 李岚松,周越,熊翔,等. 基于LS-SVM的航空故障电弧诊断[J]. 电器与能效管理技术, 2018, (10): 45-49.
LI L S, ZHOU Y, XIONG X, et al. Diagnosis of aviation fault arc based on LS-SVM[J]. Electrical and Energy Management Technology, 2018, (10): 45-49.
- [13] 高飞,董伟,桂美景,等. 基于集合经验模态分解的交流航空故障电弧识别[J]. 电工电能新技术, 2020, 39(4): 73-80.
GAO F, DONG W, GUI M J, et al. Identification of AC aviation arc fault based on ensemble empirical mode

- decomposition [J]. *Advanced Technology of Electrical Engineering and Energy*, 2020, 39(4): 73-80.
- [14] 崔芮华, 佟德栓, 李泽. 基于广义 S 变换的航空串联电弧故障检测 [J]. *中国电机工程学报*, 2021, 41(23): 8241-8250.
- CUI R H, TONG D SH, LI Z. Aviation arc fault detection based on generalized S transform [J]. *Proceedings of The CSEE*, 2021, 41(23): 8241-8250.
- [15] LIU X L, HUANG D S, JING T, et al. Detection of AC arc faults of aviation cables based on H-I-W three-dimensional features and CNN-LSTM neural network [J]. *IEEE Access*, 2022, 10: 106958-106971.
- [16] SALEH S A, ALJANKAWAY A S, ERROUSSI R, et al. Phase-based digital protection for arc flash faults [J]. *IEEE Transactions on Industry Applications*, 2016, 52(3): 2110-2121.
- [17] WANG Z Y, HAN C X, GAO H X, et al. Identification of series arc fault occurred in the three-phase motor with frequency converter load circuit via VMD and entropy-based features [J]. *IEEE Sensors Journal*, 2022, 22(24): 24320-24332.
- [18] GAO H X, WANG Z Y, HAN C X, et al. Feature extraction method of series arc fault occurred in three-phase motor with inverter circuit [J]. *IEEE Transactions on Power Electronics*, 2022, 37(9): 11164-11173.
- [19] GAO H X, WANG Z Y, TANG A X, 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] 杨冬锋, 王鹤, 刘晓军, 等. 基于 VMD-SVD 的多端柔直电网故障测距方案 [J]. *电网技术*, 2022, 46(8): 3084-3095.
- YANG D F, WANG H, LIU X J, et al. Fault location scheme for multi-terminal MMC-HVDC system based on VMD-SVD [J]. *Power System Technology*, 2022, 46(8): 3084-3095.
- [21] DRAGOMIRETSKIY K, ZOISSO D. Variational mode decomposition [J]. *IEEE Transactions on Signal Processing*, 2014, 62(3): 531-544.
- [22] ZHAO T W, WANG J, CHE J X, et al. Performance degradation prediction of proton exchange membrane fuel cell based on CEEMDAN-KPCA and DA-GRU networks [J]. *Instrumentation*, 2024, 11(1): 51-61.
- [23] 王艳松, 高鑫, 胡彩娥, 等. 基于核主成分分析和 AP 聚类算法的电力系统态势感知技术 [J]. *电测与仪表*, 2022, 59(1): 25-36.
- WANG Y S, GAO X, HU C E, et al. Power system situational awareness technology based on kernel principal component analysis and AP clustering algorithm [J]. *Electrical Measurement and Instrumentation*, 2022, 59(1): 25-36.
- [24] 覃尚昊, 胡迎春, 周明, 等. 基于改进 VMD 与特征选择的路灯故障检测方法 [J]. *电子测量技术*, 2023, 46(9): 92-99.
- TAN SH H, HU Y CH, ZHOU M, et al. Streetlight fault detection method based on improved VMD feature selection [J]. *Electronic Measurement Technology*, 2023, 46(9): 92-99.
- [25] 王强, 刘宏伟, 聂子凡. 基于 VMDT-POA-DELM-GPR 的两阶段短期负荷预测 [J]. *国外电子测量技术*, 2024, 43(1): 101-109.
- WANG Q, LIU H W, NIE Z F. Two-stage short-term load forecasting based on VMDT-POA-DELM-GPR [J]. *Foreign Electronic Measurement Technology*, 2024, 43(1): 101-109.
- [26] 刘晓明, 赵洋, 曹云东, 等. 基于小波变换的交流系统串联电弧故障诊断 [J]. *电工技术学报*, 2014, 29(1): 10-17.
- LIU X M, ZHAO Y, CAO Y D, et al. Series arc fault diagnosis based on wavelet transform in AC system [J]. *Transactions of China Electrotechnical Society*, 2014, 29(1): 10-17.
- [27] ARTALE G, CATALIOTTI A, COSENTINO V, et al. Arc fault detection method based on CZT low-frequency harmonic current analysis [J]. *IEEE Transactions on Instrumentation and Measurement*, 2017, 66(5): 888-896.

作者简介



蔡佳成(通信作者), 2013 年于辽宁工程技术大学获得学士学位, 2016 年于东北电力大学得硕士学位, 现为辽宁工程技术大学讲师, 主要研究方向为电器基础理论及应用。

E-mail: caijiacheng_lntu@163.com

Cai Jiacheng (Corresponding author) received his B. Sc. degree from Liaoning Technical University in 2013, M. Sc. degree from Northeast Electric Power University in 2016, respectively. Now he is a lecturer in Liaoning Technical University. His main research interests include basic theory and technology of electrical apparatus.