

基于自组织特征映射网络的电弧故障检测方法

林靖怡^{1,2}, 王尧^{1,2}, 李奎^{1,2}, 田明^{1,2}

(1. 河北工业大学 省部共建电工装备可靠性与智能化国家重点实验室, 天津 300130;

2. 河北工业大学 河北省电磁场与电器可靠性重点实验室, 天津 300130)

摘要:一般利用故障电弧产生时的电流波形特性进行电弧故障检测。随着线路负载种类的日益增多,故障电弧产生时的电流波形与某些负载无弧情况下的电流波形十分相似,难以通过简单的电流时频域特征进行电弧故障检测,影响电弧故障检测的准确性。针对该问题,提出一种自组织特征映射网络与滑窗法相结合的电弧故障检测方法,在自组织特征映射网络自主挖掘电流数据内在特征的基础上,利用相邻周期电流样本之间的关联性与连续性,对电流信号进行连续检测,提高电弧故障检测准确率。所提方法能有效实现电弧故障检测,电弧故障检测准确率可达99%。

关键词:故障电弧; 电流波形; 自组织特征映射网络; 滑窗法; 电弧故障检测

中图分类号: TM 501+.2

文献标志码: A

DOI: 10.16081/j.epae.202006028

0 引言

随着家庭用电量和工业负荷不断增多,电气火灾事故发生率逐年增长,威胁着人们的日常生活安全。故障电弧是引起电气火灾的主要原因之一,传统的过流保护方法无法对故障电弧进行有效保护。根据电弧故障在线路中的发生位置,可以将其划分为串联电弧故障、并联电弧故障与接地电弧故障3类。其中,串联电弧故障产生的电流通常比线路的正常负载电流小,导致过流保护器不能发现并切断故障^[1-3]。因此,对串联电弧故障保护方法的研究具有重大意义。

目前,电弧故障主要通过故障电弧电流的时域特征、频域特征或时频域特征进行检测,涉及傅里叶变换、小波分解、支持向量机与神经网络等复杂运算^[3-4]。文献[5]提出小波变换与奇异值分解的方法,对电流信号进行离散小波变换构造特征矩阵,利用对特征矩阵进行奇异值分解所得的特征参数进行电弧故障判断。文献[6]提出一种基于短时过零率与模式识别算法的电弧故障检测方法,能有效利用电弧故障信息实现电弧故障的检测与分类。文献[7]利用分形维数表征高频电流信号特性,以常见分形维数中的盒维数与关联维数构造特征向量,通过支持向量机对串联电弧故障状态进行判断。文献[8]提出一种基于多分辨率的快速小波变换电弧故障检测方法,将采样负载电流分解为低频信号与高频信号,通过重构小波高频系数有效识别电弧故障状态。文献[9]通过对采样数据进行快速傅里叶变

换,分析频谱结果并以此为基础筛选多个特征值进行交流电弧故障检测。

当前电弧故障检测方法主要依赖特征量的选择,常用的时域特征包含电流半波不对称、电流有效值和变化率改变等,频域特征包含电流频谱各次谐波含量、相角与总谐波畸变率等,时频域特征主要为经小波分解后的电流特征^[10]。而故障电弧的电流特性通常随线路中负载的改变而变化,即使在同样的负载条件下,特征也不完全相同^[11],例如电机类负载与电子类负载无电弧故障时的电流波形与纯阻性负载出现电弧故障时的电流波形十分相似,难以通过常用的时频域电流特征量准确检测电弧故障。机器学习具有强大的归纳学习、分析学习和类比学习的能力,可以从大数据中准确提取特征、挖掘内在规律,在文字处理、图像识别、语音辨识、故障检测等领域得到了广泛应用和发展^[12-15]。聚类分析的方法是一种应用较为广泛的可用于研究样品或指标分类的多元统计方法,其可以将性质相似的个体归为一类^[16]。自组织特征映射网络是机器学习中以K-means聚类算法为基础的一种神经网络学习算法,能自主地从庞大的样本集合中提取特征量,并对样本进行分类,比K-means聚类算法更稳定^[17]。

本文提出一种基于自组织特征映射网络的串联电弧故障检测方法,与传统检测方法相比,本文方法利用竞争学习算法自主提取特征量,能更大程度地挖掘电流潜在特征,对于不同负载条件下的线路电流均适用。

1 自组织特征映射网络

1.1 自组织特征映射网络理论

自组织特征映射网络是1981年由荷兰学者Teuvo Kohonen提出的一种可以进行无监督学习的

收稿日期:2019-09-28;修回日期:2020-05-04

基金项目:国家自然科学基金资助项目(51607055)

Project supported by the National Natural Science Foundation of China(51607055)

网络,其可以将输入的高维向量空间映射至二维平面。与其他神经网络不同,自组织特征映射网络只有由输入层与输出层构成的双层结构。输出层又称竞争层,各神经元间有着相互竞争的关系。但与一般的竞争层网络不同,自组织特征映射网络中每个神经元均与附近的神经元之间存在关联,若某个神经元权值更新,其周围神经元的权值也会发生变化。

自组织特征映射网络模型如图 1 所示,输入层中的神经元个数 k 代表输入向量的维数大小,输出层的每一个神经元都与输入层神经元通过权值相连。

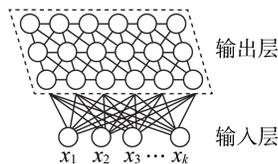


图 1 自组织特征映射网络模型示意图

Fig.1 Schematic diagram of self-organizing feature mapping network model

将 k 维输入向量 $\mathbf{X} = (x_1, x_2, \dots, x_k)^T$ 输入自组织特征映射网络后,采用 $[0, 1]$ 区间内的随机数作为输入层与输出层之间的初始权值,通过计算找到与 \mathbf{X} 具有最小欧氏距离的输出层神经元权值向量,修正该神经元与周围神经元的权值参数,使网络输出达到预设要求^[11,18]。

应用自组织特征映射网络进行分类的步骤如下:

- (1) 选取合适的样本作为训练集;
- (2) 通过学习,用不同类型记号标记有最大输出的神经元,构成训练好的自组织特征映射网络;
- (3) 将验证集样本输入自组织特征映射网络;
- (4) 对比输出层中输出神经元的位置与训练好的自组织特征映射网络中样本的位置,通过计算欧氏距离最终确定验证集样本的输出值。

1.2 自组织特征映射网络串联电弧故障检测方法

进行串联电弧故障检测时,自组织特征映射网络的输入样本为试验采集的一维电流数据,自组织特征映射网络通过修正神经元之间的权值参数,归纳和发掘样本之间的潜在特性,能有效处理输入类型复杂、特征不明显的数据^[11]。

自组织特征映射网络根据输出类别的概率值对电流输入样本进行分类,检测输入样本是否发生串联电弧故障。设网络共有 N 种输出类别,输入样本通过网络得到其属于每一种输出类别的概率值,设第 i 种输出类别的概率为 P_i ,所有输出类别概率值之和 $\sum_{i=1}^N P_i = 1$ 。 N 种输出类别概率值中的最高值和次高值分别记为 P_m 和 P_s ,概率值为 P_m 的类别为该电流

样本的最终输出类别。每种输出类别均对应负载有串联电弧故障或无电弧故障的情况,自组织特征映射网络完成对输入样本的分类后,根据分类结果判断输入样本是否发生串联电弧故障,完成串联电弧故障检测。

1.3 自组织特征映射网络串联电弧故障检测改进方法

自组织特征映射网络通过判断电流样本属于各输出类别的概率,进行分类与串联电弧故障检测。当概率值最高的输出类别与概率值次高的输出类别概率值接近时,自组织特征映射网络判断输入样本为这 2 种输出类别的可能性都较高,即输出类别中概率最高值与次高值之差 $P_m - P_s$ 越小,自组织特征映射网络分类时产生错误的概率越大。

虽然线路电流波形在刚发生串联电弧故障时会突然改变,但故障发生之前与发生故障之后长时间内的电流波形不会突变,相邻的电流样本之间存在关联性与连续性。本文基于电流波形短时平稳的假设,提出滑窗法与自组织特征映射网络相结合的串联电弧故障检测方法,在滑窗法的各窗口时间内结合 $P_m - P_s$ 值,针对有较大概率分类错误的输入样本进行连续多次检测,基本检测思路如下。

(1) 从起始时刻,将一组被测电流样本分为 M 段进行检测,每段样本长为 L 、间隔为 S ,各段被测电流样本记为 $\mathbf{X}_1 = (x_i, x_{i+1}, x_{i+2}, \dots, x_{i+L-1})^T$ 、 $\mathbf{X}_2 = (x_{i+S}, x_{i+1+S}, x_{i+2+S}, \dots, x_{i+L-1+S})^T$ 、 \dots 、 $\mathbf{X}_M = (x_{i+(M-1)S}, x_{i+1+(M-1)S}, x_{i+2+(M-1)S}, \dots, x_{i+L-1+(M-1)S})^T$ 。

(2) 通过自组织特征映射网络,在第 1 个窗口时间内根据 \mathbf{X}_1 进行网络输出类别判断。

(3) 若根据 \mathbf{X}_1 得到的 $P_m - P_s \geq T_1$ (T_1 为判定值),则输出 P_m 对应的输出类别判断结果,包括负载类别和有无串联电弧故障发生;否则认为根据 \mathbf{X}_1 无法做出输出类别的判断,需要在第 2 个窗口时间内根据步骤(4)、(5)进行判断。

(4) 为了基于 \mathbf{X}_1 类别判断结果提升 \mathbf{X}_2 类别判断的准确性,根据固定属性权重策略,与相邻故障模式相关性高的属性取较大的权重^[19]。设第 1 个窗口时间内根据 \mathbf{X}_1 被判断为无电弧故障和有串联电弧故障的概率值之和分别为 ω_1 和 ω_2 。在第 2 个窗口时间内根据 \mathbf{X}_2 进行判断,判断为无电弧故障情况的概率值均与 ω_1 相乘,判断为有串联电弧故障情况的概率值均与 ω_2 相乘,将所得概率值按同比例放大至第 2 个窗口时间内的所有输出类别的概率和为 1,得到 \mathbf{X}_2 对应的网络输出类别。

(5) 若根据 \mathbf{X}_2 得到的 $P_m - P_s \geq T_2$ (T_2 为判定值),则输出 P_m 对应的输出类别判断结果;否则在下一窗口时间内对输出类别进行判断。

(6) 重复步骤(4)、(5),依次对第 3、4、 \dots 、 M 个窗

口时间内的输入样本进行检测,并判断输出类别。若发现有串联电弧故障则进行保护,若未发现电弧故障,则循环步骤(1)~(5)。

2 串联电弧故障试验

2.1 数据采集

串联电弧故障检测装置如图2所示,其包括交流电源、负载、开关、故障电弧发生器及数据采集装置五部分。根据国家标准GB/T 31143—2014《电弧故障保护电器(AFDD)的一般要求》^[20],检测装置采用220 V、50 Hz电源供电,与典型的家用电器负载通过负载插座连接。故障电弧发生器包括步进电机控制系统、铜棒移动电极以及石墨固定电极,步进电机的控制单元可以调节两电极间距离,产生稳定燃烧的电弧。通过示波器以每秒 6×10^7 个采样点的采样频率将电弧数据存储在逗号分隔值(CSV)格式文件。负载包含23 Ω 电阻与国家标准中规定的2200 W空压机型电容启动电动机、1380 W带通用电机的真空吸尘器、40 W电子荧光灯、600 W电子调光灯、690 W电子式开关电源、300 W卤素灯并联5 A电阻和600 W电钻,分别采集各负载有无电弧故障时的线路电流数据。

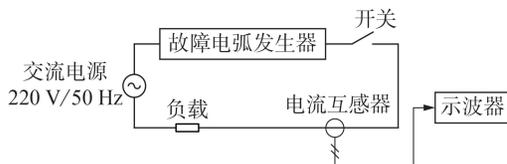


图2 串联电弧故障检测装置

Fig.2 Series arc fault detection device

2.2 数据预处理

为消除数据采集时不同负载状态下线路电流的幅值大小、采集时间长度不统一对分类结果的影响,对采集到的电流数据进行以下预处理:

(1)将电流数据分为“有弧”、“无弧”数据集,删除空白数据、重复数据与测量装置导致采集效果不好的数据;

(2)对电流数据进行归一化,将不同负载种类的电流数据幅值归一至 $[-1, 1]$ 范围内;

(3)选择时间长度相同的线路电流数据作为样本输入自组织特征映射网络;

(4)标记不同工作状态、不同负载种类的电流数据,对各负载无电弧故障和有串联电弧故障的电流值分别进行编号,样本编号情况如表1所示。

2.3 电流数据分析

对预处理后的电流数据进行分析。图3为典型的纯阻性负载条件下的电流(标么值)波形。由图可见,无电弧故障时的电流波形为光滑的正弦波;发生

表1 串联电弧故障试验编号

负载工作状态	工作状态编号	负载种类	数据样本数量	试验编号
有串联电弧故障	[1]	电阻	50	1
		空压机型电容启动电动机	50	2
		真空吸尘器	50	3
		电子荧光灯	50	4
		电子调光灯	50	5
		电子式开关电源	50	6
		电钻	50	7
		卤素灯并联电阻	50	8
无电弧故障	[2]	电阻	50	9
		空压机型电容启动电动机	50	10
		真空吸尘器	50	11
		电子荧光灯	50	12
		电子调光灯	50	13
		电子式开关电源	50	14
		电钻	50	15
		卤素灯并联电阻	50	16

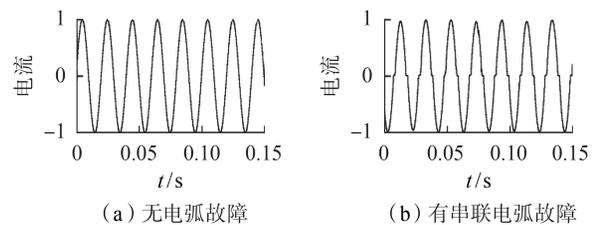


图3 纯阻性负载无电弧故障与有串联电弧故障时的电流

Fig.3 Current of resistive loads under normal and series arc fault conditions

串联电弧故障时,受交变电流的影响,电弧在电流值为0时能量最小而自动熄灭,随着电压换向,电弧在一段时间后重燃。电弧的熄灭时间即电流值为0的时间,电流波形表现为在过零点附近有零休区间。

卤素灯由白炽灯改进而来,在工作过程中需要给灯丝导通足够的电流,加热灯丝至白炽状态。卤素灯并联电阻电流波形如附录中的图A1所示,由图可见,无电弧故障时的电流波形为正弦波,发生串联电弧故障后电流波形出现零休区间。

真空吸尘器的控制电路含有大量感性元件和非线性滤波元件,无电弧故障时其电流波形有零休区间,发生串联电弧故障时电流幅值波动明显,平肩部过度较为缓和,并伴有高次谐波,典型真空吸尘器电流波形图见附录中的图A2。

电钻由于电机工作时存在磁路饱和等问题,在无电弧故障时电流波形近似三角波,包含不同程度的高次谐波,发生串联电弧故障时电流波形在无电弧故障时的电流波形的基础上出现较为稳定的零休区间。典型的电钻电流波形图见附录中的图A3。

空压机型电容启动电动机为单相感应电动机,定子上有空间位置相差 90° 的启动绕组与工作绕组。多数情况下两相绕组不对称,谐波分量较多,无电弧

故障时的电流波形发生畸变,发生串联电弧故障时电流波形有明显的零休区间,电流幅值波动较大,增减不定。典型的空压机型电容启动电动机电流波形图见附录中的图 A4。

荧光灯利用汞蒸气电离形成气体放电,使荧光粉发光,属于低气压弧光放电光源,无电弧故障时的电流波形存在类似零休区间,发生串联电弧故障后电流波形过零时间变长,零休区间特征明显。荧光灯电流波形图见附录中的图 A5。

电子调光灯通过调节晶闸管导通角改变输出电压,起到调光作用。非线性电力电子装置导致电子调光灯在无电弧故障时的电流波形发生畸变,发生串联电弧故障时的电流波形出现高频毛刺,电子调光灯电流波形见附录中的图 A6。

开关电源的工作原理与线性电源不同,通过改变电子开关器件的开断时间比率,对输入电压进行调制。无电弧故障时,开关电源受电子开关器件的影响,二极管导通角变小,电流波形畸变为周期性尖峰电流,有稳定的零休区间,发生串联电弧故障后电流波形的零休区间高次谐波减少。典型的开关电源电流波形图见附录中的图 A7。

传统电弧故障检测方法为提取电流特征量,利用电弧故障与特征量之间的映射关系进行判断。但不同负载的工作原理不同,某一负载在无弧情况下的电流特征,可能与其他负载发生电弧故障时的电流特征相同。实际运行中的负载类型复杂多样,难以通过简单的电流时频域特征进行电弧故障判断。而自组织特征映射网络可以对不同负载条件下的电流波形产生不同的响应,通过反复调节神经元的权重系数,实现相同神经元的聚集,能在负载类型复杂多样的情况下自主发掘合适的特征量,从而进行串联电弧故障检测。

3 串联电弧故障检测结果

3.1 自组织特征映射网络串联电弧故障检测结果

自组织特征映射网络可以提取输入数据的内在特征,学习输入向量的拓扑结构,自动地对输入数据进行分类。研究故障电弧电流特性通常需要连续几个周期,既要有效分析串联电弧故障特性,还要避免网络算法运算量过大,故本文选择以 3 个工频周期作为 1 个时间长度的电流输入样本进行串联电弧故障检测。取 8 种负载在无电弧故障与有串联电弧故障情况下的一维电流数据各 50 组作为网络输入样本,按表 1 分别编号为 1—16 输入训练好的自组织特征映射网络进行检测,网络输出类别即为分类结果。为验证网络分类效果,将电流样本输入类别编号与输出类别编号进行对比,统计输入样本被判别为各输出类别的样本个数如附录中的图 A8 所示。

图中,横坐标为样本的输入类别,即样本的实际类别,纵坐标对应样本通过自组织特征映射网络判断的输出类别;对角线和非对角线上的数字分别为分类正确和分类错误的样本个数;百分数为横坐标所代表的各种类负载分类的准确率。每组电流样本输入自组织特征映射网络后,得到该样本分别属于 16 种输出类别的概率值。“无弧组”数据被分类至“有弧组”会引起电弧故障断路器误判、“有弧组”数据被分类至“无弧组”会引起电弧故障断路器拒判,均会导致无法正确检测串联电弧故障。由图 A8 可计算得到自组织特征映射网络对 800 组输入样本负载种类分类的准确率为 93.9%,串联电弧故障检测的准确率为 96.8%。由图 A8 得到的误判与拒判结果如表 2 所示。

表 2 误判与拒判结果

判别情况	网络输入类别	网络输出类别	数量
拒判	电子荧光灯	电钻	3
	电子调光灯	电钻	3
	电钻	真空吸尘器	4
		电钻	1
误判	真空吸尘器	真空吸尘器	4
		电子式开关电源	4
	电子调光灯	卤素灯并联电阻	2
		空压机型电容启动电动机	5

3.2 改进方法的串联电弧故障检测结果

基于滑窗的自组织特征映射网络串联电弧故障检测方法需要通过长度固定、随时间滑动的窗口选择电流输入样本,在每个滑窗内进行串联电弧故障检测。根据国家标准有关 AFDD 分断时间及限制值的规定,不同等级试验电弧电流条件下 AFDD 的最短分断时间为 0.12 s。本文以 3 个工频周期作为 1 个窗口时间、1 个工频周期作为窗口的滑动步长为例,在 0.1 s 内连续检测 3 个窗口时间的电流样本,以验证改进算法的串联电弧故障检测结果。

图 A8 中负载类型未分类正确的样本总数为 49,分类错误样本的输出类别概率值 P_m 与 P_s 之差见表 3,表中 r_{false} 为样本数占分类错误总样本数的百分比。由表 3 可以看出, $P_m - P_s$ 越小,样本分类发生错误的概率越大, $P_m - P_s$ 可以作为电弧检测方法中判断是否需要采用滑窗法对输入电流连续检测的判断标准。

表 3 分类错误电流样本的 $P_m - P_s$ 的关系

$P_m - P_s$	分类错误 样本数	$r_{false} / \%$	$P_m - P_s$	分类错误 样本数	$r_{false} / \%$
[0.3, 1]	0	0	[0.01, 0.05)	19	38.8
[0.15, 0.3)	6	12.2	[0, 0.01)	10	20.4
[0.05, 0.15)	14	28.6			

串联电弧故障检测过程中,判定值的选择十分重要,一般用判别概率的最大值作为判别的依据。然而,采用判别概率的最大值作为判别的依据时,若只经过一次自组织特征映射网络进行分类,分类错误较多。根据表3中 P_m-P_s 与分类错误率的对应关系,选择0.3作为第1个窗口时间内的判定值。当输入电流数据经过自组织映射网络进行分类后,若第1个窗口时间内的 $P_m-P_s>0.3$,则表示串联电弧故障检测准确度极高,输出 P_m 对应的输出类别判断结果,否则需要在下一窗口时间内继续进行判断。模式识别中的聚类分析可以针对不同的输入对象采用不同的量化方式进行划分,通过算法自动寻找最优分类点作为判定值。以 P_m-P_s 作为输入量,使用K-means聚类算法进行聚类,通过计算输入值之间的欧氏距离,对分类错误样本的 P_m-P_s 分布疏密程度进行划分。针对 P_m-P_s 属于不同疏密区间的样本,采用不同的输出类别概率值计算方法以提高故障检测准确率。根据图4所示的分类错误电流样本聚类结果,将0.12作为第2个窗口时间内的判定值,当 $P_m-P_s<0.12$ 时需要在下一窗口时间内进行进一步的判断。最后一个窗口时间内以判别概率的最大值为判定值,输出最后一个窗口时间内的 P_m 对应的类别作为最终的判断结果。

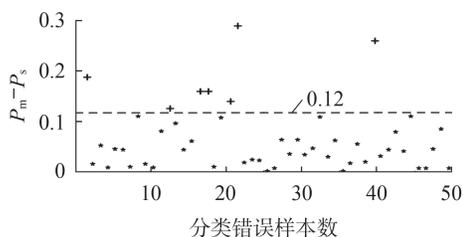


图4 分类错误电流样本的 P_m-P_s 聚类结果

Fig.4 Clustering results of P_m-P_s of incorrectly classified current samples

实际中,在表2所列的8种自组织特征映射网络易发生判断错误的情况下,电弧故障断路器会发生拒判与误判。将这8种情况设定为易错情况,例如 P_m 与 P_s 分别对应电子荧光灯与电钻时,需要重点进行判断。

采用自组织特征映射网络进行串联电弧故障检测的过程中,3个窗口时间下网络输出类别概率值的最高值和次高值分别计为 $P_m(1)$ 、 $P_m(2)$ 、 $P_m(3)$ 和 $P_s(1)$ 、 $P_s(2)$ 、 $P_s(3)$ 。改进后自组织特征映射网络的串联电弧故障检测流程图见附录中的图A9。

电流数据进入自组织特征映射网络后,根据 $P_m(1)-P_s(1)$ 判定是否需要再下一窗口继续进行判断。若需要在第2个窗口时间内继续进行判断,则计算第1个窗口时间内的 ω_1 和 ω_2 。第2个窗口时间内输出类别的概率值按照其所属无电弧故障、有

串联电弧故障的情况,分别与 ω_1 、 ω_2 相乘,按同比例放大至所有概率值之和为1,得到 $P_m(2)$ 和 $P_s(2)$ 。若 $P_m(2)-P_s(2)>0.12$,比较 $P_m(1)$ 与 $P_m(2)$ 大小,输出概率较高值所对应的类别。若 $P_m(2)-P_s(2)<0.12$,判断 $P_m(2)$ 、 $P_s(2)$ 所代表的类别是否属于表2中的易错情况:若属于易错情况,则在第3个窗口时间内计算前3个窗口时间下各输出类别概率值的平均值,比较得到最大值并输出相应的类别;若不属于易错情况,则计算前2个窗口时间内各输出类别概率值的平均值,比较得出最大值并输出相应的类别。选取800组已知负载类型的电流样本作为训练集对改进后的自组织特征映射网络进行训练。

重新选取400组未知负载类型和有无串联电弧故障发生情况下的电流样本进行验证,负载类型包括真空吸尘器、电子荧光灯、电子调光灯、电子式开关电源、电钻等8种常用负载,输入改进前、后的自组织特征映射网络进行分类。在网络完成分类后,统计串联电弧故障检测错误数据,计算串联电弧故障检测准确率,不同负载类型下的检测结果如表4所示。表中, r_{ac} 为自组织特征映射网络电弧故障检测准确率。

表4 不同负载的串联电弧故障检测结果

Table 4 Test results of series arc fault detection under different loads

负载类型	$r_{ac}/\%$		负载类型	$r_{ac}/\%$	
	改进前	改进后		改进前	改进后
电阻	98	100	电子调光灯	92	100
空压机型电容启动电动机	98	100	电子式开关电源	96	98
真空吸尘器	84	98	电钻	94	98
电子荧光灯	98	98	卤素灯并联电阻	94	100

根据不同负载的串联电弧故障检测结果,在电阻、空压机型电容启动电动机、真空吸尘器、电子调光灯、电子式开关电源、电钻、卤素灯并联电阻这7类负载条件下,改进后的自组织特征映射网络的串联电弧故障检测准确率均高于改进前的自组织特征映射网络。改进前自组织特征映射网络串联电弧故障检测准确率为94.3%,改进后的自组织特征映射网络串联电弧故障检测准确率可达99%,相较于改进前有较大的提升。

在国家标准规定的串联电弧故障试验条件下,针对采用线电流时频域典型特征进行检测的某品牌电弧故障断路器样品进行测试,验证样品在电路中突然出现串联电弧故障时的正确动作、接入带串联电弧故障负载的正确动作和闭合串联电弧故障时的正确动作情况。试验所用负载为阻性负载,样品通过检测线路中的高频信号识别串联电弧故障。试验采用3台样品进行测试,每项试验根据规定的预期

电弧电流(3、6、13、20、40、63 A)重复进行3次,采集测试时的样品电流数据,并整理样品测试结果如表5所示。

表5 电弧故障断路器样品测试结果

Table 5 Test results of arc fault detection device

样品	正确动作次数	错误动作次数	正确动作率 / %
1	47	7	87.0
2	48	6	88.9
3	44	10	81.5

根据表5所示的某品牌电弧故障断路器样品测试结果,3台测试样品的正确动作概率分别为87.0%、88.9%、81.5%,将样品测试时采集的电流数据输入改进后的自组织映射网络进行电弧故障检测,电弧故障检测准确率为100%,能够有效识别串联电弧故障。

4 结论

本文针对不同类型负载导致电弧故障特征不同,难以通过某一特征值准确判断电弧故障的问题,提出了一种基于自组织特征映射网络的电弧故障检测方法,并得到以下结论。

(1)传统电弧故障检测方法一般采用常规电弧故障电流特征量进行判断,由于线路中负载工作原理各异、类型复杂多样,难以解决误判和拒判问题。

(2)在分析多种常用负载线路电流波形特征的基础上,提出改进的串联电弧故障检测方法。采用滑窗法对输入自组织特征映射网络的电流数据进行连续检测。根据每次窗口时间内的检测结果及其相对应的概率大小,得到最终的检测结果。试验结果表明,改进后的自组织特征映射网络电弧故障检测准确率可达99%。

(3)本文方法能在负载类型复杂多样的情况下,利用自组织特征映射网络自主确定合适的特征量,进行电弧故障检测,简单易行、准确率高。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

[1] POR C S, CHOO K L, JIAN L Y. A study of arc fault current in low voltage switchboard[C]//2012 IEEE Conference on Sustainable Utilization and Development in Engineering and Technology (STUDENT). Kuala Lumpur, Malaysia: IEEE, 2012: 52-56.

[2] 陈德桂. 低压电弧故障断路器:一种新型低压保护电器[J]. 低压电器, 2007(3): 7-9.
CHEN Degui. The arc-fault circuit interrupter: a new low voltage protection apparatus[J]. Low Voltage Apparatus, 2007(3): 7-9.

[3] 王尧, 韦强强, 葛磊蛟, 等. 基于电弧电流高频分量的串联交流电弧故障检测方法[J]. 电力自动化设备, 2017, 37(7): 191-197.
WANG Yao, WEI Qiangqiang, GE Leijiao, et al. Series AC arc fault detection based on high-frequency components of arc

current[J]. Electric Power Automation Equipment, 2017, 37(7): 191-197.

- [4] 王晓远, 高森, 赵玉双. 阻性负载下低压故障电弧特性分析[J]. 电力自动化设备, 2015, 35(5): 106-110, 118.
WANG Xiaoyuan, GAO Miao, ZHAO Yushuang. Characteristic analysis of low-voltage arc fault in resistive load conditions [J]. Electric Power Automation Equipment, 2015, 35(5): 106-110, 118.
- [5] 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.
- [6] 刘晓明, 徐叶飞, 刘婷, 等. 基于电流信号短时过零率的电弧故障检测[J]. 电工技术学报, 2015, 30(13): 125-133.
LIU Xiaoming, XU Yefei, LIU Ting, et al. The arc fault detection based on the current signal short time zero crossing rate [J]. Transactions of China Electrotechnical Society, 2015, 30(13): 125-133.
- [7] 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.
- [8] DUAN P, XU L, DING X, et al. An arc fault diagnostic method for low voltage lines using the difference of wavelet coefficients[C]//2014 9th IEEE Conference on Industrial Electronics and Applications. Hangzhou, China: IEEE, 2014: 401-405.
- [9] 丁鑫, 竺红卫, 殷浩楠, 等. 基于快速傅里叶变换(FFT)的交流电器电弧快速检测法[J]. 电器与能效管理技术, 2015(21): 8-12.
DING Xin, ZHU Hongwei, YIN Haonan, et al. Fast detection method for AC arc based on FFT [J]. Electrical & Energy Management Technology, 2015(21): 8-12.
- [10] 王尧, 田明, 牛峰, 等. 低压交流电弧故障检测方法研究综述[J]. 电器与能效管理技术, 2018(10): 8-13, 44.
WANG Yao, TIAN Ming, NIU Feng, et al. A comprehensive review of arc fault detection methods for low voltage AC power system [J]. Electrical & Energy Management Technology, 2018(10): 8-13, 44.
- [11] 邹云峰, 吴为麟, 李智勇. 基于自组织映射神经网络的低压故障电弧聚类分析[J]. 仪器仪表学报, 2010, 31(3): 571-576.
ZOU Yunfeng, WU Weilin, LI Zhiyong. Cluster analysis of arc fault in low-voltage based on SOM neural network [J]. Chinese Journal of Scientific Instrument, 2010, 31(3): 571-576.
- [12] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets [J]. Neural Computation, 2006, 18(7): 1527-1554.
- [13] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. DeepLab: semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018, 40(4): 834-848.
- [14] LECUN Y, BENGIO Y, HINTON G. Deep learning [J]. Nature, 2015, 521(7553): 436-444.
- [15] ZHANG Z X, GEIGER J, POHJALAINEN J, et al. Deep learning for environmentally robust speech recognition [J]. ACM Transactions on Intelligent Systems and Technology, 2018, 9(5): 1-28.
- [16] 吴礼斌, 李柏年. MATLAB数据分析方法[M]. 北京: 机械工业

出版社,2018:187-215.

- [17] 刘春晓. 基于SOM和PSO的聚类算法研究[D]. 成都:西南交通大学,2009.

LIU Chunxiao. Clustering algorithm based on SOM and PSO [D]. Chengdu:Southwest Jiaotong University,2009.

- [18] 刘艳,陈丽安. 基于SOM的真空断路器机械故障诊断[J]. 电工技术学报,2017,32(5):49-54.

LIU Yan,CHEN Li'an. Mechanical fault diagnosis of vacuum circuit breaker based on SOM[J]. Transactions of China Electrotechnical Society,2017,32(5):49-54.

- [19] 雷杰,徐晓滨,徐晓健,等. 基于置信规则库的并发故障诊断方法[J]. 系统工程与电子技术,2020,42(2):497-504.

LEI Jie,XU Xiaobin,XU Xiaojian,et al. Concurrent fault diagnosis method based on belief rule base[J]. Systems Engineering and Electronic,2020,42(2):497-504.

- [20] 全国低压电器标准化技术委员会. 电弧故障保护电器(AFDD)的一般要求:GB/T 31143—2014[S]. 北京:中国标准出版社,

2014.

作者简介:



林靖怡

林靖怡(1993—),女,河北石家庄人,硕士研究生,主要研究方向为电器智能化(E-mail:lin.jingyi.hebut@gamil.com);

王尧(1981—),男,河北石家庄人,副教授,博士,主要研究方向为电器智能化技术与电器设备电磁兼容(E-mail:wycolor@163.com);

李奎(1965—),男,河北保定人,教授,博士研究生导师,通信作者,主要研究方向为开关设备与可靠性智能化(E-mail:likui@hebut.edu.cn);

田明(1994—),女,河北廊坊人,硕士研究生,主要研究方向为电弧故障检测(E-mail:tiasweet@163.com)。

(编辑 任思思)

Arc fault detection method based on self-organizing feature mapping network

LIN Jingyi^{1,2},WANG Yao^{1,2},LI Kui^{1,2},TIAN Ming^{1,2}

(1. State Key Laboratory of Reliability and Intelligence of Electrical Equipment, Hebei University of Technology,Tianjin 300130,China;

2. Key Laboratory of Electromagnetic Field and Electrical Apparatus Reliability of Hebei Province, Hebei University of Technology,Tianjin 300130,China)

Abstract: Fault arcs are generally identified by characteristics of the current waveform when arc faults occur. As the types of loads are increasing, the fault current waveforms are very similar to the current waveforms of some loads without arc. It is difficult to detect the arc fault by the simple time or frequency domain characteristics of the current, which affects the accuracy of the arc fault detection. In order to solve this problem, an arc fault detection method of combining self-organizing feature mapping network with sliding window method is proposed. Based on the intrinsic characteristics of current data obtained by the self-organizing feature mapping network, by making use of the correlation and continuity between the adjacent periodic current samples, the current signal is detected continuously to improve the accuracy of arc fault detection. The proposed method can effectively detect the arc fault, and the accuracy of arc fault detection reaches 99%.

Key words: fault arcs; current waveform; self-organizing feature mapping network; sliding window method; arc fault detection

附录

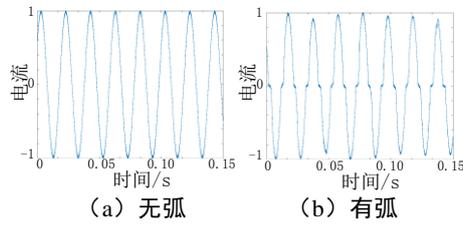


图 A1 卤素灯无弧与有弧电流

Fig.A1 Current of halogen lamp under normal and arc fault conditions

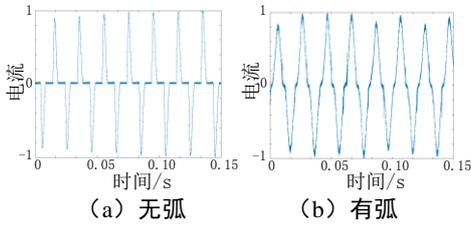


图 A2 真空吸尘器无弧与有弧电流

Fig.A2 Current of vacuum cleaner under normal and arc fault conditions

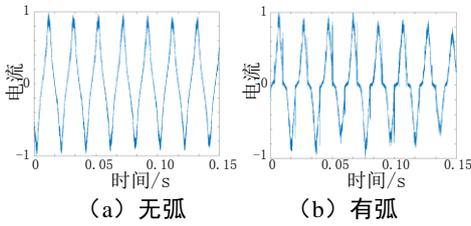


图 A3 电钻无弧与有弧电流

Fig.A3 Current of electric drill under normal and arc fault conditions

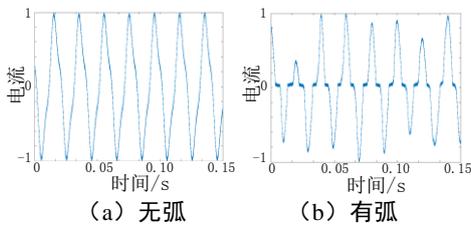


图 A4 空压机型电容启动电动机无弧与有弧电流

Fig.A4 Current of air compressor type capacitor starter motor under normal and arc fault conditions

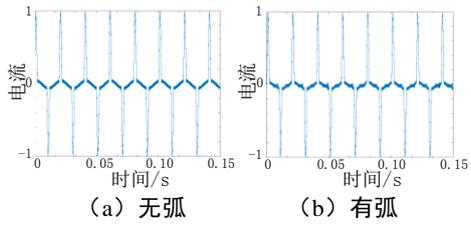


图 A5 荧光灯无弧与有弧电流

Fig.A5 Current of fluorescent lamp under normal and arc fault conditions

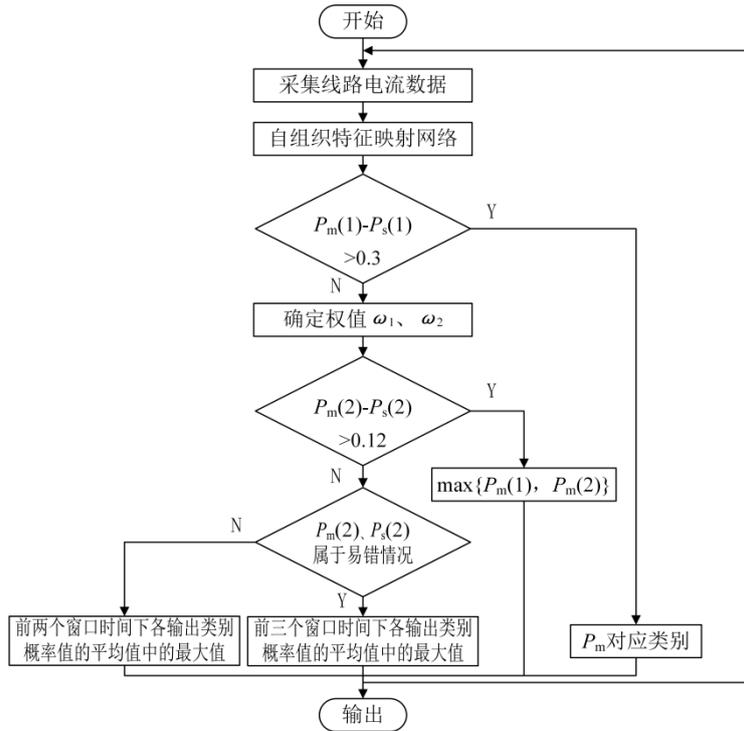


图 A9 电弧故障检测流程图

Fig.A9 Flow chart of arc fault detection