

基于多特征融合和 SVM 的串联电弧故障检测方法

郭敏^{1,2}, 吴宁^{1,2}, 郭小璇^{1,2}, 卢健斌^{1,2}, 陈卫东^{1,2}

(1. 广西电网有限责任公司电力科学研究院, 南宁 530023;

2. 广西电力装备智能控制与运维重点实验室, 南宁 535023)

摘要: 针对现有的传统电气保护装置无法对串联电弧故障进行有效检测的问题, 本文提出一种基于多特征融合和改进 SVM 的串联电弧故障检测方法。首先, 通过搭建电弧故障平台进行电弧实验, 获得典型负载在电路正常运行及发生电弧故障时的电流信号; 然后, 对采集到的电流信号进行时域、频域和时频域分析, 构建串联电弧特征指标集; 最后, 将串联电弧特征指标集作为 SVM 的输入向量, 并利用粒子群算法对 SVM 进行优化, 提高分类模型的准确率。测试结果表明, 采用本文所提方法进行串联故障电弧识别的准确率达到 95% 以上。

关键词: 串联电弧; 故障识别; 特征提取; 支持向量机; 粒子群算法

Series Arc Fault Detection Method Based on Multi-feature Fusion and SVM

GUO Min^{1,2}, WU Ning^{1,2}, GUO Xiaoxuan^{1,2}, LU Jianbin^{1,2}, CHEN Weidong^{1,2}

(1. Electric Power Research Institute of Guangxi Power Grid Co., Ltd., Nanning 530023, China;

2. Guangxi Key Laboratory of Intelligent Control and Maintenance of Power Equipment,
Nanning 535023, China)

Abstract: For the problem that the existing traditional electrical protection device cannot effectively detect the series arc fault, a kind of series arc fault detection method based on multi-feature fusion and improved SVM is proposed in this paper. Firstly, the arc experiment is performed by setting up an arc fault platform, the current signal of typical loads during normal operation and arc faults are obtained; Then, the collected current signals are subjected to time domain, frequency domain and time-frequency domain analysis to construct series arc feature index set; Finally, the series arc feature index set is taken as the input vector of SVM, and the particle swarm algorithm is used to optimize the SVM so to improve the accuracy of the classification model. The test results show that the accuracy rate of series faults arc identification using the the method proposed in this paper reaches more than 95%.

Keywords: series arc fault; fault recognition; feature extraction; SVM; PSO

0 引言

电力的普及和应用大大加快了人类社会的发展和水平进步, 在人类社会的发展史上有着重要意义。近半个世纪以来, 新型负载的不断涌现和广泛应用, 使得家庭用电量和工业用电量持续增加, 配电系统的负荷也在不断加大, 随之而来的是低压配电网中的用电安全问题。电气火灾是引发火灾的首要原因, 持续严重威胁着人类的生命安全以及社会的经济发展。在引发电气火灾的起因中,

电弧故障不容忽视^[1]。

电弧故障是指由于电气线路或设备中绝缘老化破损、电气连接松动、电压电流急剧升高等原因引起空气击穿所导致的气体游离放电现象, 其具有明显的局域性和突发性、发展快、破坏性强、持续时间短等特点, 不利于传统用电保护装置的准确识别及预报。按照电弧故障在电路中发生位置的不同通常可将其分为 3 种类型: 串联型电弧故障、并联型电弧故障、对地电弧故障^[2]。大多数时候, 传统电气保护装置如熔断器、断路器、剩余电流动作保护

装置能够对并联型电弧和对地电弧进行有效检测识别,但在串联电弧故障发生时,由于电路电流的减少,导致熔断器、断路器等无法发生动作,最终引发火灾。因此,研究有效的串联电弧故障检测方法,规避串联电弧故障造成的损失和危害是十分必要的。

国内外电弧故障检测的方法主要是根据电流、电压波形来分析,由于基于电流的电弧故障检测方法不需要提前确定电弧故障的位置,因此一般采用电流波形对电弧故障进行检测^[3]。目前基于电流波形的串联电弧故障检测方法主要可分为时域、频域和时频域的检测方法^[4],文献[5-7]基于电流波形的时域特征,分别利用电流的峰值变化、相邻电流周波间的差异值和电流信号的短时过零率对故障电弧进行检测。电流的时域特征易于提取,检测直观有效,但稳定性差,易受噪音的干扰。为了避免时域特征的不足,文献[8-10]基于电流波形的频域特征,分别利用电流高次谐波含有率、电流高频分量和谐波差分来检测电弧故障。频域特征的提取通常需要利用傅里叶变化,但傅里叶变化在处理非平稳信号时只关注了信号的频域特征,忽视了局部时频特性,针对这一问题,文献[11-13]基于电流波形的时频特性,利用小波变换理论进行电弧特征量的提取。小波变换解决了傅里叶变换在局部时域信号分析方面的不足,更适合对电流信号的不规则程度进行描述,但小波变换存在着频谱混叠的问题,仅依靠小波系数对电弧进行检测会丢失较多的电弧信息。

因此,单一特征并不足以实现对串联故障电弧的有效诊断,为解决这一问题,文献[14]根据串联电弧故障的奇异性、能量特性以及不确定性进行特征提取,将以往对单特征量的识别转换为对多特征空间位置分布关系的研究,并利用改进的BP神经网络实现对串联电弧故障的准确诊断。文献[15]基于提取的Fourier系数、Mel频率倒谱数据和小波特征建立多特征融合神经网络算法,能够更全面地对电弧故障进行诊断。文献[16]提取零休息时间、电流变化速率、电流平均值的绝对值、电流周期性、谐波因素、总谐波畸变率、子代能量比和频率质心作为代价敏感神经网络的输入量来识别故障电弧。文献[17]提出一种时频域分析与随机森林结合的诊断识别方法对电弧进行故障识别。

因此,本文对原始实验数据集进行时域、频域和时频域分析,建立了多特征融合算法。在分类器方面,基于SVM算法模型,并利用PSO优化算法提高了模型的准确率。

1 串联电弧故障实验

1.1 电流信号采集

基于UL1699标准的相关规定,本文搭建串联

故障电弧实验平台用于电弧实验,电弧故障实验电路图见图1,其中电弧故障发生器由一个石墨圆棒和一个尖头铜棒组成,数据采集卡的采样频率为10 kHz,电源为220 V 50 Hz的交流电。




图1 串联电弧故障实验电路图
Fig. 1 Experimental circuit diagram of series arc fault

本文对一些典型的单个负载进行实验,在采集正常电流信息时,保持石墨圆棒和尖头铜棒之间的接触;在采集故障信息时,通过分离石墨圆棒和尖头铜棒模拟产生故障电弧。表1为本文实验采集电流信息时接入的负载。

表1 实验所用负载类型
Table 1 Type of load for the experiment

序号	负载	负载类型
1	荧光灯 10 W	电容-电感类
2	荧光灯 20 W	电容-电感类
3	空调	电容-电感类
4	调光灯	电容-电感类
5	冰箱	电容-电感类
6	吹风机 1 500 W	电阻类
7	烧水壶	电阻类
8	手机	开关类
9	电脑	开关类
10	吹风机 800 W	开关类

1.2 电流波形分析

通过重复实验得到各典型负载在正常工作时和发生电弧故障后的电流数据,取各负载的正常状态和故障状态时的各5个周期对电流波形进行分析,电流波形见图2,其中图2(a)代表荧光灯10 W,图2(b)代表荧光灯20 W,图2(c)代表空调,图2(d)代表调光灯,图2(e)代表冰箱,图2(f)代表吹风机1 500 W,图2(g)代表烧水壶,图2(h)代表手机,图2(i)代表电脑,图2(j)代表吹风机800 W。

从图2可以看出,电弧发生前各类负载的电流有规则的波形并具有周期性,电弧发生后各类负载的电流波形普遍发生畸变、幅值范围发生改变且出现了高次谐波。




图2 负载正常电流和故障电流波形

Fig. 2 Load normal current and fault current waveforms

对于实验所用的电阻类负载来说,正常工作电流有规则的波形,发生电弧故障后在零点附近普遍出现明显的平肩部,电流幅值变小,平肩部过后电流的斜率增大,并且出现高次谐波;对于实验所用的电容-电感类和开关类负载来说,电弧电流并没有像电阻类负载那样表现出相同的特征,各有各的特点:1)一些负载发生电弧后平肩部增大较为明显,但有些负载由于正常工作时也会出现平肩部,

因此平肩部的变化并不明显。2)电弧发生后电流出现高次谐波,个别周期电流波形畸变严重,在部分区间变化速度加快,电流幅值波动。经过以上分析可知,由于不同负载在发生电弧后所具备的特征不尽相同,因此仅依靠电流的时域特征并不能有效区分正常电流和电弧故障电流。

2 电弧故障特征的分析 and 提取

一般来说,为了更大程度的提高对串联电弧故障的诊断识别能力,需要从实验得到的电流信息中提取更有代表性、更有用的特征。由于仅依靠单一特征并不足以实现对所有负载的诊断识别,因此,本文在电弧多特征融合的基础上,在电流的时域、频域以及时频域进行特征提取。

2.1 时域特征提取

本文提取的时域特征包括零休时间、电流的移动平均值、电流的移动方差以及电流变化率的平均值^[7]。

零休时间是指每个周期内电流波形在零点附近电流瞬时值连续等于零的时间,通常以“平肩部”表现出来。将周期内连续处于零点附近的采样点数表示零休时间,公式为

$$t_{\text{zero}} = \sum_{k=1}^{N-1} \text{dif}_k \quad (1)$$

$$\begin{cases} \text{dif}_k = 1, & |l_k| < 0.3 \text{ A 且 } |l_k - l_{k-1}| < 0.15 \text{ A} \\ \text{dif}_k = 0, & \text{其他} \end{cases}$$

式中, $\text{dif}_k = 1$ 表示该采样点处于零休状态, $\text{dif}_k = 0$ 表示该采样点不处于零休状态, l_k 表示该采样点的电流瞬时值。

电流的移动平均值 x_{mean} 、电流的移动方差 x_{var} 以及电流变化率(x_{var})的平均值的公式为

$$x_{\text{mean}} = \frac{1}{N} \sum_{i=1}^N x_i \quad (2)$$

$$x_{\text{var}} = \frac{1}{N-1} \sum_{i=1}^N (x_i - x_{\text{mean}})^2 \quad (3)$$

$$x_{\text{ave}} = \frac{1}{N} \sum_{i=1}^{N-1} \frac{|x_{i+1} - x_i|}{\Delta t} \quad (4)$$

式中: N 为一个周期内电流的采样个数; x_i 表示该周期内第 i 个电流数据; Δt 为该周期内相邻电流样本之间的时间间隔。

根据公式求得荧光灯 10 W、荧光灯 20 W、空调等 10 种负载不同状态下的零休时间、电流的移动平均值、电流的移动方差以及电流变化率的平均值。图 3 为电容-电感类负载的时域特征图,图 4 为电阻类负载的时域特征图,图 5 为开关类负载的时域特征图。




图3 电容-电感类负载的时域特征图
Fig. 3 Time domain characteristic diagram of capacitive-inductive loads




图4 电阻类负载的时域特征图
Fig. 4 Time domain characteristic diagram of resistive loads




图5 开关类负载的时域特征图

Fig. 5 Time domain characteristic diagram of a switching load

由图 3-5 可知,在发生电弧故障后,不同类型负载的时域特征变化情况存在差异,而且即使是同一类负载的时域特征变化情况也不尽相同,并且部分负载在不同电路状态下的时域特征取值区间存在重叠:1)在发生电弧故障时,3 种类型负载的零休时间是普遍增大的,但手机的零休时间是减小的,并且空调的零休时间与正常工作时的取值区间存在重叠;2)在发生电弧故障时,3 种类型负载的移动方差是普遍减小的,但手机的移动方差是增大的,并且空调的移动方差与正常工作时的取值区间存在重叠;3)对于移动平均值和变化率平均值来说,在发生电弧故障时,不同负载类型的变化情况明显不同,并且不同电路状态下的取值区间重叠现象更为明显。因此,仅依靠时域特征进行诊断识别并不适用于所有负载类型。

2.2 频域特征提取

对电流进行特征分析是一种常见的信号分析手段,为了消除不同负载类型带来的影响,本文在进行特征分析之前先将电流信号归一化到[0,1]区间,然后进行快速傅里叶变换(FFT),离散式的 FFT 公式为

$$X(k) = \sum_{n=0}^{N-1} x(n)e^{-j2\pi kn/N}, 0 \leq k \leq N-1 \quad (5)$$

式中, N 为采样信号 $x(n)$ 的大小。

由 1.2 章节可知,发生电弧故障时电流波形会出现大量高次谐波,与正常电流区别明显。图 6 为不同负载电流正常工作时的和发生电弧故障后的频谱图,由快速傅里叶变换得到,为了更好地体现频带细节,该频谱图只包含了 20 次谐波。图 6 左边各图为各负载正常工作时的频谱图,右边为各负载电弧故障时的频谱图,经过对各负载不同电路状态下频谱图的比较,得到以下结论:

1)正常工作状态下:电阻类负载的频谱以基波为主,其它次谐波较少;电容-电感类负载和开关类的频谱在基波上的幅值仍然最大,但次谐波情况不尽相同:①荧光灯 20W、空调、冰箱以及吹风机 800W 的高次谐波现象不明显。②荧光灯 10W、调光灯、手机以及电脑的高次谐波现象较为明显。

2)在电弧故障状态下,不同负载的各次谐波变化不同,但普遍来看,电流的谐波总量有所变化,基波和奇次谐波的变化较为明显,主要表现在 3 次、5 次谐波处。




图6 不同负载电流频谱图

Fig. 6 Spectrogram of different load currents

因此,本文将基波、3次谐波、5次谐波、频谱平均值以及频谱标准差作为分类模型的输入量。

频谱平均值 X_{mean} 和频谱方差 X_{var} 的计算公

式为

$$X_{\text{mean}} = \frac{1}{N} \sum_{i=1}^N X_i \quad (6)$$

$$X_{\text{var}} = \frac{1}{N-1} \sum_{i=1}^N (X_i - X_{\text{mean}})^2 \quad (7)$$

式中: X_i 为第 i 个频谱点的幅值; N 为一个电流周期的频谱长度。

2.3 时频域特征提取

小波变换和傅里叶变换都是检测电弧故障的典型信息处理方法。小波变换继承和发展了傅里叶变换的思想,更适用于信号的时频分析和处理。连续小波变换(CWT)公式为

$$\text{CWT}(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} f(t) \psi^*\left(\frac{t-b}{a}\right) dt \quad a, b \in R, a \neq 0 \quad (8)$$

其中

$$\psi_{a,b}^* = \frac{1}{\sqrt{|a|}} \psi^*\left(\frac{t-b}{a}\right) \quad (9)$$

式中: $f(t)$ 为任意能量有限信号; $\psi(t)$ 为母小波或基本小波; a 和 b 分别为尺度因子和位移因子。


离散小波变换(DWT)是连续小波变换的离散化,适应于离散信号的处理,公式为

$$\text{DWT}(m, n) = \frac{1}{\sqrt{2^m}} \int_{-\infty}^{+\infty} f(t) \psi^*\left(\frac{t-2^m n}{2^m}\right) dt \quad m, n \in Z \quad (10)$$


式中, n 和 m 分别表示时间和频率。

小波基 $\psi(t)$ 的选取是小波分析的关键步骤,在同一个问题中,小波基不同,得到的分析结果也不一致。常用的小波基有 Daubechies (dbN) 小波、Haar 小波、Morlet 小波以及 Meyer 小波等,由于 Daubechies 小波具有良好的连续性、正交性和紧支性,且对不规则信号更加敏感的特点,被广泛应用于信号分析领域^[18]。因此,本文通过对比 db 小波系中 db₃、db₅ 以及 db₇ 3 种小波基函数对电流信号的分解效果,发现 db₃ 小波在不规则特征提取及实时性上较好,故使用 db₃ 小波对电弧电流进行 4 层分解得到逼近信号与细节信号。

图 7 为 10 个周期内 db₃ 小波基对荧光灯 10 W 正常工作和发生电弧故障下电流信号进行 4 层小波变换细节图,图 8 为 10 个周期内电脑正常工作和发生电弧故障下电流信号小波变换细节图, d_1 , d_2 , d_3 , d_4 分别为小波变换的 4 层细节系数。通过图 7-8 可以看出, d_2 层细节系数能够很好地反映电弧电流的变化特点,因此,本文提取 d_2 层细节系数平均值 m_{mean} 、 d_2 层细节系数方差 m_{var} 、 d_2 层小波系数峰值 m_{max} 以及 d_2 层细节变化系数 $(m'_k)^{[18]}$ 作为特征量。



(a) 荧光灯 10 W 正常电流波形



(b) 荧光灯 10 W 故障电流波形

图7 荧光灯 10 W 小波变换 4 层分解小波系数

Fig. 7 TWavelet coefficients of four layers decomposition through wavelet transform in Fluorescent lamp of 10 W




图8 电脑小波变换4层分解小波系数

Fig. 8 Wavelet coefficients of four layers decomposition through wavelet transform in computer

$$m_{\text{mean}} = \frac{1}{N} \sum_{i=1}^N S_i \quad (11)$$

$$m_{\text{var}} = \frac{1}{N-1} \sum_{i=1}^N (S_i - m_{\text{mean}}) \quad (12)$$

$$m_{\max} = \max(S_i) \quad (13)$$

式中: S_i 为该周期内小波细节系数第 i 个采样点的取值; N 为一个周期内的总采样点数。

细节变化系数 m'_k 的定义为相邻周期细节系数的相关变化量,其表达式为

$$m'_k = \frac{m_{k+1} - m_k}{m_{k+1}} \quad (14)$$

$$m_k = \frac{\sum_{i=1}^N |S_k^i|}{N}$$

式中, S_k^i 为小波细节系数第 k 个周期第 i 个采样点的取值。

3 多特征融合SVM串联电弧故障识别方法

3.1 串联电弧故障检测SVM粒子群优化模型

支持向量机(SVM)是一种对样本进行二分类的模型,通过在空间中寻找合适的超平面使得两样本间的隔离边缘被最大化,从而实现对两个样本的分类,其最优化问题的基本公式为

$$\min_{\alpha} \frac{1}{2} \sum_{i=1}^j \sum_{j=1}^l y_i y_j \alpha_i \alpha_j K(x_i, x_j) - \sum_{j=1}^l \alpha_j \quad (15)$$

$$\text{s.t. } \sum_{i=1}^l y_i \alpha_i = 0, 0 \leq \alpha_i \leq C, i = 1, \dots, l$$

式中: $K(x, x')$ 为核函数; C 为惩罚因子; x_i 为特征向量; $y_i \in Y = \{1, 0\}$ 。

对SVM来说,核函数的选择是构建模型的关键,核函数决定SVM的性能。大多数情况下,无法构造完全适合样本空间的核函数,因此通常会直接使用一些常见的核函数,如:线性核函数、多项式核函数、高斯(RBF)核函数以及sigmoid核函数等。由于RBF核函数在处理非线性映射方面较有优势,并且参数较少,因此本文选取RBF函数作为SVM的核函数。

在使用RBF核函数时,需要考虑惩罚因子 C 和核函数参数 g 的取值, C 和 g 的选取会影响SVM的精度、收敛速度以及预测值。目前常用的SVM参数优化选择方法包括交叉验证方法(CV)以及网格搜索等。CV方法有多种变种, K -fold cross validation (K -CV)就是一种常见的CV方法,其基本思想是将原始数据集划分为 K 组,每一次取1组数据子集作为测试集(不重复取),其余 $K-1$ 组作为训练集,由此生成 K 个模型,并将 K 个模型相应测试集的分类准确率的平均数作为此 K -CV 下模型的性能指标。 K -CV 可以有效避免SVM模型过学习以及欠

学习情况的发生。网格搜索是一种超参数搜索算法,使用简单,应用广泛,但因为需要固定步长,搜索时容易跨过最优参数点,无法实现全局最优。而粒子群算法(particle swarm optimization, PSO)是模拟鸟类觅食行为的群体智能优化算法^[19-21],可通过寻找最优种群收敛到全局最优,因此本文在构建分类模型时使用PSO对传统SVM模型的惩罚因子 C 和核函数参数 g 进行优化,并利用 K -CV 意义下的准确率作为SVM模型的性能指标,从而有效提高SVM模型对故障电弧的诊断准确率。




图9 PSO-SVM模型流程图
Fig. 9 Flowchart of PSO-SVM

图9为使用PSO对串联电弧故障检测SVM模型优化的流程图,具体步骤如下:

- 1) 将经过预处理的电弧特征指标集 X 划分为训练集和测试集,并基于训练集生成SVM模型;
- 2) 将训练集作为原始数据集并利用 K -CV 得到的分类准确率作为衡量SVM模型性能优劣的标准;
- 3) 粒子群初始化。在一定的范围内随机产生一组参数对 (C, g) 作为粒子的初始位置。设定最大迭代次数为200,种群数为20,终止迭代误差为0.1;
- 4) 将各参数对 (C, g) 下的交叉验证分类准确率作为粒子群算法的适应度函数值,并通过跟踪当前参数对 (C, g) 下的个体极值 P_{best} 和群体极值 G_{best} 更新个体位置;
- 5) 当个体极值与群体极值之间的误差小于终止迭代误差时,将此时的 (C, g) 作为最佳的惩罚因子 C 和核函数参数 g ;

6)利用最佳参数对(C,g)训练 SVM 模型,生成 PSO-SVM 模型,并完成对测试集的预测。

3.2 SVM粒子群优化算法识别串联故障电弧的流程

首先,通过电弧故障实验收集各典型负载在发生电弧故障前后的电流波形,并提取电流波形的时域、频域以及时频域特征作为输入特征量,并对其进行归一化处理,构建电弧特征指标集;然后,将电弧特征指标集作为 SVM 的输入向量,并使用 PSO 对 SVM 的惩罚因子 C 和核函数参数 g 进行优化,构建 PSO-SVM 优化模型,并利用此模型对串联电弧故障进行诊断识别。

4 结果与分析

4.1 实验结果

在 Matlab 2021b 平台使用 LIBSVM 工具箱建立串联电弧故障检测的 SVM 模型,在此模型中使用 RBF 函数作为该模型的核函数,进行电弧数据的诊断识别。本实验的电流波形样本数据是经过电弧故障实验得到,并通过对电流时域、频域以及时频域的特征提取,得到电弧特征指标数据集。电弧特征指标数据集的容量为 1 800 组(训练集设定为 1 260 组,测试集为 540 组),其中每种负载的正常数据和故障数据各 100 组,包括空调、烧水壶、冰箱、调光灯、电脑、吹风机 1 500 W、荧光灯 10 W、荧光灯 20 W 以及真空吸尘器这 9 种负载,并且特征指标数据集的输入维度为 13。

图 10 为传统 SVM 模型对故障电弧的分类结果,其惩罚因子 C 和核函数测试 g 的取值分别为 1 和 0.1。由图可知,传统 SVM 模型对测试集的分类准确率为 94.629 6%,其中对测试数据中的 11 个正常样本和 18 个故障样本产生了误判。




图 10 SVM 的分类结果
Fig. 10 Classification results for SVM

图 11 为使用 BP 神经网络算法对故障电弧的分类结果,其学习率和训练次数的取值分别为 0.01 和 200。由图可知,BP 神经网络对测试集的分类准确率为 95.185 2%,其中对测试数据中的 8 个正常样本和 18 个故障样本产生了误判。




图 11 BP 神经网络的分类结果
Fig. 11 Classification results of BP neural networks

图 12 为使用 PSO 优化算法对传统 SVM 模型优化改进后的适应度变化曲线,其中,交叉验证的折数为 5。由图可知,随着迭代次数的增大,粒子群的最佳适应度有所提高,并在进化次数 50 之前最佳适应度趋于稳定。使用 PSO 算法搜索到的最佳参数组合为惩罚因子 C=67.138 7,核函数参数 g=0.755 58,并且该模型的交叉验证准确率为 97.222 2%。




图 12 PSO 优化的 SVM 适应度曲线
Fig. 12 Adaptability curve of SVM optimized by PSO

图 13 为 PSO-SVM 模型对故障电弧的分类结果,由图可知,当惩罚因子 C=67.138 7,核函数参数 g=0.755 58 时,PSO-SVM 模型对测试集的分类准确率为 98.518 5%,其中对测试数据中的 3 个正常样本和 5 个故障样本产生了误判。相较于传统 SVM

模型和BP神经网络,PSO-SVM模型的准确率更高,分别提高了将近5%和3%。




图13 PSO-SVM的分类结果
Fig. 13 Classification results for PSO-SVM

4.2 性能评价指标

常用的性能评价指标有准确率(Accuracy)、查全率(Recall)以及查准率(Precision),可通过混淆矩阵的相关计算得到。混淆矩阵的构造见表2,上述3个指标的计算公式分别为

$$\text{Accuracy} = \frac{TP + TN}{TN + FN + FP + TP} \tag{16}$$

$$\text{Recall} = \frac{TP}{TP + FP} \tag{17}$$

$$\text{Precision} = \frac{TP}{TP + FN} \tag{18}$$

表2 混淆矩阵
Table 2 Confusion matrix

预测类		真实类
0(故障)	1(正常)	
TP	FP	0(故障)
FN	TN	1(正常)

为了更好地显示本文 PSO-SVM 优化模型对各类负载诊断识别的有效性,选取未参与训练的各负载在发生电弧故障前后的电流信号各 50 组(一共 900 组)作为测试集,并与传统 SVM 算法、BP 神经网络进行比较,其中,SVM 的核函数为 RBF 函数,惩罚因子 C 设为 1,核函数参数 g 设为 0.1;BP 神经网络学习率设为 0.01,训练次数为 500。表 3 为上述 3 种分类模型对各负载的准确率,表 4 为 3 种分类模型对各负载的查全率,表 5 为 3 种分类模型对各负载的查准率。从上述 3 张表可知,相较传统 SVM 以及 BP 神经网络,本文使用的 PSO-SVM 优化算法对各负载都有更好的准确率、查全率以及查

准率,能够更好地对串联电弧故障进行诊断识别。

表3 3种分类模型对各负载的准确率
Table 3 Accuracy rate of three classification models for each load

负载	传统SVM/%	BP神经网络/%	PSO-SVM/%
空调	95	100	100
冰箱	96	97	99
吹风机 1 500 W	83	91	96
电脑	99	99	100
调光灯	99	98	98
烧水壶	96	99	98
荧光灯 10 W	97	97	99
荧光灯 20 W	90	91	99
真空吸尘器	94	97	99

表4 3种分类模型对各负载的查全率
Table 4 Recall rate of the three classification models for each load

负载	传统SVM/%	BP神经网络/%	PSO-SVM/%
空调	98	100	100
冰箱	96	96	100
吹风机 1 500 W	80	84	94
电脑	98	98	100
调光灯	100	98	98
烧水壶	96	100	100
荧光灯 10 W	100	98	100
荧光灯 20 W	82	88	100
真空吸尘器	100	98	100

表5 3种分类模型对各负载的查准率
Table 5 Precision rate of three classification models for each load

负载	传统SVM/%	BP神经网络/%	PSO-SVM/%
空调	92.45	100.00	100.00
冰箱	96.00	97.96	98.04
吹风机 1 500 W	85.11	97.67	97.92
电脑	100.00	100.00	100.00
调光灯	98.04	98.00	98.00
烧水壶	96.00	98.04	96.15
荧光灯 10 W	94.34	96.08	98.04
荧光灯 20 W	97.62	93.62	98.04
真空吸尘器	89.29	96.08	98.04

另外,为了验证本文方法对未知负载串联电弧故障的诊断识别能力,选取未参与模型构建的吹风机 800 W 和荧光灯 45 W 发生电弧故障前后的电流信号各 100 组作为测试集,其分类准确率分别为 82%和 83.5%,并且随着更多不同负载类型参与模型的训练,其准确率可进一步提高。因此,本文方法对未知负载也具有一定的诊断识别能力。

5 结语

1)本文采用了电流的时域、频域以及时频域作为 SVM 粒子群优化算法模型的输入特征量,相较于单一特征,基于多特征融合的分析方法能够更全面地对串联电弧故障进行检测。

2)在 SVM 训练模型中,以 K-CV 意义下的准确率作为 SVM 模型的性能指标,并采用 PSO 算法对 SVM 的惩罚因子 C 以及核函数参数 g 进行优化,提高模型的准确率。

3)提出的多特征融合 SVM 粒子群优化算法与传统 SVM 算法以及 BP 神经网络相比,具有更高的准确率、查全率以及查准率,能够实现对串联电弧故障的有效诊断。

参考文献

- [1] 刘晓明,王丽君,赵洋,等. 串联故障电弧检测方法的研究[J]. 电气开关,2014,52(1):13-18.
LIU Xiaoming, WANG Lijun, ZHAO Yang, et al. Research on the detection method of series arc fault[J]. Electric Switcher, 2014, 52(1): 13-18.
- [2] GREGORY G D, WONG K, DVORAK R. More about arc-fault circuit interrupters[C]//38th IAS Annual Meeting on Conference Record of the Industry Applications Conference, 2003. [S.l.]: IEEE, 2003(2): 1306-1313.
- [3] ZENG Ke, XING Lidong, ZHANG Yaojia, et al. Characteristics analysis of AC arc fault in time and frequency domain [C]//2017 Prognostics and System Health Management Conference (PHM-Harbin). [S. l.]: IEEE, 2017: 1-5.
- [4] 崔芮华,李泽,佟德栓. 基于三维熵距和熵空间的航空电弧故障检测与分类技术[J]. 电工技术学报, 2021, 36(4): 869-880.
CUI Ruihua, LI Ze, TONG Deshuan. Arc fault detection and classification based on three-dimensional entropy distance and entropy space in aviation power system[J]. Transactions of China Electrotechnical Society, 2021, 36(4): 869-880.
- [5] JIANG Jun, WEN Zhe, ZHAO Mingxin, et al. Series arc detection and complex load recognition based on principal component analysis and support vector machine[J]. IEEE Access, 2019(7): 47221-47229.
- [6] 朱森,孙鹏. 基于周波分析法的串联型故障电弧诊断技术[J]. 电气技术, 2016(2): 46-48.
ZHU Sen, SUN Peng. The series fault arc detection method based on cycle analysis[J]. Electrical Engineering, 2016(2): 46-48.
- [7] 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.
- [8] 廖水容,张认成,李夏河. 低压串联电弧故障电流高次谐波含有率试验[J]. 河南理工大学学报(自然科学版), 2013, 32(2): 179-182.
LIAO Shuirong, ZHANG Rencheng, LI Xiahe. Experiment on current high order harmonic ratio for series low voltage arc fault[J]. Journal of Henan Polytechnic University (Natural Science), 2013, 32(2): 179-182.
- [9] 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.
- [10] LEE W J, SAHNI M, METHAPRAYOON K, et al. A novel approach for arcing fault detection for medium-/low-voltage switchgear[J]. IEEE Transactions on Industry Applications, 2009, 45(4): 1475-1483.
- [11] 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 Xiaoming, ZHAO Yang, CAO Yundong, et al. Series arc fault diagnosis based on wavelet transform in AC system [J]. Transactions of China Electrotechnical Society, 2014, 29(1): 10-17.
- [12] 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. Series arc fault detection method based on wavelet transform and singular value decomposition[J]. Transactions of China Electrotechnical Society, 2017, 32(17): 208-217.
- [13] 郭凤仪,李坤,陈昌垦,等. 基于小波近似熵的串联电弧故障识别方法[J]. 电工技术学报, 2016, 31(24): 164-172.
GUO Fengyi, LI Kun, CHEN Changken, et al. Series arc fault identification method based on wavelet approximate entropy[J]. Transactions of China Electrotechnical Society, 2016, 31(24): 164-172.
- [14] 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 Xiaoming, ZHAO Yang, CAO Yundong, et al. Multi-feature fusion based diagnosis of series arc faults in AC system[J]. Power System Technology, 2014, 38(3): 795-801.
- [15] 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 Guanwei, MU Haibao, ZHANG Daning, et al. Series arc fault detection technology based on multi-feature fusion neural network[J]. High Voltage Engineering, 2021, 47(2): 463-471.
- [16] 殷浩楠, 竺红卫, 丁鑫, 等. 一种基于代价敏感学习的故障电弧识别方法[J]. 传感器与微系统, 2018, 37(4): 13-16.
- YIN Haonan, ZHU Hongwei, DING Xin, et al. An arc-fault recognition method based on cost - sensitive learning[J]. Transducer and Microsystem Technologies, 2018, 37(4): 13-16.
- [17] 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 Yi, CHEN Jin, LI Songnong, 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.
- [18] 孔林娟. 基于突变理论的低压故障电弧检测方法研究[D]. 焦作: 河南理工大学, 2015.
- [19] 程学新. 粒子群优化加权随机森林算法研究[D]. 郑州: 郑州大学, 2017.
- [20] 唐俊. PSO 算法原理及应用[J]. 计算机技术与发展, 2010, 20(2): 213-216.
- TANG Jun. Principle and application of PSO algorithm[J]. Computer Technology and Development, 2010, 20(2): 213-216.
- [21] 张丽萍. 粒子群优化算法的理论及实践[D]. 杭州: 浙江大学, 2005.
- 作者简介:**
- 郭敏(1984—), 男, 高级工程师, 主要研究方向为电力电子、电能质量和无功电压分析与控制技术。E-mail: 329106373@qq.com。
- 吴宁(1991—), 男, 工程师, 主要研究方向为综合能源技术应用研究。E-mail: wu_n.sy@gx.csg.cn。
- 郭小璇(1986—), 女, 高级工程师, 通信作者, 主要研究方向为需求侧管理及电能替代技术。E-mail: guo_xx.sy@gx.csg.cn。
- 卢健斌(1991—), 男, 工程师, 主要研究方向为智慧用能技术。E-mail: lu_jb.sy@gx.csg.cn。
- 陈卫东(1983—), 男, 高级工程师, 主要研究方向为微电网及电能质量的分析与控制技术。E-mail: chen_wd.sy@gx.csg.cn。