

DOI:10.12158/j.2096-3203.2019.05.001

计及雷击情况的基于 PDT-SVM 暂降源辨识方法研究

李陶然¹, 张宸宇², 史明明², 沙浩源¹, 郑建勇¹, 梅飞³

(1. 东南大学电气工程学院, 江苏 南京 210096; 2. 国网江苏省电力有限公司电力科学研究院, 江苏 南京 211103; 3. 河海大学能源与电气学院, 江苏 南京 210098)

摘要:目前,电压暂降已成为影响最突出的电能质量问题之一,为有效分析雷击对电网暂降的影响程度,对雷击导致电压暂降的情况进行了详细分析,准确辨识了包括雷击导致暂降情况在内的4种暂降类型,为合理划分暂降责任提供重要依据。文中首先分析了雷击故障导致暂降的有效值波形与普通短路故障之间的区别,归纳了短路故障、雷击、变压器投切及感应电机启动4种暂降类型电压有效值波形的特点,引入5个暂降电压特征指标,并建立了暂降类型辨识特征矩阵。然后采用基于粒子群聚类优化的决策树支持向量机(PDT-SVM)分类器对4种暂降类型进行辨识。分类器的训练与测试数据均来自电网实测暂降电压数据,与工程实际密切贴合。最后,算例分析结果验证了算法的有效性和准确性。

关键词:雷击;电压暂降;有效值;特征辨识;SVM

中图分类号:TM714

文献标志码:A

文章编号:2096-3203(2019)05-0002-06

0 引言

我国的经济中心地处于东部沿海地区,受气候影响,雷雨天气频繁,尤其是长江三角洲地区的落雷密度较大,给电网的安全运行带来威胁^[1-4]。根据配电网电压暂降监测系统上传的数据来看,入夏以来,雷击导致短路故障而引发电压暂降数量大幅上升,已成为电网暂降发生的重要影响因素之一。相对于主网来说,配电网的绝缘保护较为薄弱,直击雷可轻易击穿配电系统的防雷设施,导致系统发生短路故障,这不仅会影响配电系统的供电质量,还可能导致严重事故的发生^[5]。因此,有必要对雷击引发的短路故障进行区分,统计分析地区雷击导致暂降发生的频次、密度、特点及影响因素,进而为配电网的防雷规划及防雷改造决策提供有力的数据支撑。

目前对于配电网电压暂降类型辨识的研究中只讨论了短路故障(ordinary short circuit fault, SC)、感应电机启动(induction motor starting, MS)和变压器投切(transformer switching, TS)3种类型^[6-9],并没有将雷击故障(faults caused by lightning strikes, LS)导致暂降的情况与普通短路故障情况区分出来,忽略了LS的特殊性,对LS情况的特征研究还较为欠缺。

以江苏电网暂降监测终端上传的实际暂降数据为基础,文中首先对雷击导致暂降的波形特点进

行分析并与普通短路故障情况进行了对比分析,根据暂降期间电压有效值波形,分析归纳各主要暂降类型特征。建立暂降辨识特征矩阵并采用基于粒子群聚类优化的决策树支持向量机(decision tree support vector machine based on particle swarm clustering optimization, PDT-SVM)进行辨识暂降类型辨识。最后,利用实际监测数据验证了暂降辨识算法的有效性及其准确性。

1 暂降类型特征分析

1.1 雷击导致暂降的特征分析

雷击主要可分为非故障性雷击和故障性雷击两大类。非故障性雷击的雷电流幅值小,电网可在短时间内恢复,危害并不严重。故障性雷击是指线路上雷击过电压超过线路绝缘的耐受水平,使线路绝缘遭到破坏并发生闪络,从而导致系统跳闸或设备损坏的情况^[10-11]。雷击故障多为瞬时性故障,故障发生后变电站内操动机构多数能在短时间内自动切除故障线路,重合闸完成后便可恢复供电,重合闸成功率在70%~90%(对永久性故障不做讨论)^[12-13]。LS与SC暂降电压有效值波形如图1所示,其中 U 为电压幅值。

由图1(a)可知,LS有效值波形中含有很大的高频谐波分量,波形无规则且伴随着很多突变尖峰。在暂降初始过程中,电压幅值先有一段快速上升的阶段(如黑色线条局部细节图所示),随后才进入下降过程。这是由于雷电波在配电线路传播时,母线间行波的折反射与监测点处的电压叠加而导

收稿日期:2019-03-21;修回日期:2019-04-27

基金项目:江苏省重点研发计划资助项目(BE2017030)




图 1 LS 与 SC 暂降电压有效值波形

Fig.1 Lightning voltage sag and ordinary short circuit voltage sag RMS waveforms

致,随后在短路故障的影响下,波形先上升后下降。普通短路故障暂降情况(即图 1(b))中电压波形就不存在该过程。因此,LS 波形的特征可总结为:电压有效值波形先上升后下降,谐波含量高,暂降幅值深。

1.2 暂降的特征量选择

根据江苏电网实测波形数据,4 种主要的暂降源类型包括 LS、SC、TS、MS。典型波形如图 1(a),(b)和图 2(a),(b)所示。因此,对以上暂降源典型波形特点的归纳如表 1 所示。

结合上述波形特征分析,引入 5 个暂降特征指标,如表 2 所示。其中, k_1, k_2 分别为暂降的起始对应采样点和恢复对应采样点; U 为电压有效值; K 为暂降起止时刻间的采样点数; n 为谐波次数; U_n 为 n 次谐波电压幅值; U_d 为基波电压幅值。特征指标表达式如表 2 所示。





图 2 TS 与 MS 暂降电压有效值波形

Fig. 2 Transformer switching voltage sag and induction motor starting voltage sag RMS waveforms

表 1 暂降源波形特点

Table 1 Characteristics of the sag waveform

类型	特征归纳		
	幅值/p.u.	谐波	波形特点
TS	≥ 0.85	包含 2 次谐波分量	暂降开始阶段电压波形陡峭,但恢复过程缓慢。
SC	≤ 0.7	不包含	持续时间与保护动作时间有关;电压波形变化过程呈矩形。
LS	无规律	包含高次谐波	电压有效值波形先上升后下降。
MS	≥ 0.85	不包含	暂降过程平滑切持续时间较长。

表 2 特征值表达式

Table 2 Eigenvalue expressions

编号	特征指标	表达式
1	三角形系数	$F_1 = \frac{(U(k_1) - U_{\min})(k_2 - k_1)}{2 \left[(k_2 - k_1)U(k_1) - \sum_{k=k_1}^{k_2} U(k) \right]}$
2	波峰系数	$F_2 = \frac{\max(U(k))}{\sqrt{\frac{1}{K} \sum_{k=k_1}^{k_2} U^2(k)}}$
3	均方根值	$F_3 = \sqrt{\frac{1}{K} \sum_{k=k_1}^{k_2} (U(k) - \bar{U})^2}$
4	偏度	$F_4 = \frac{1}{(K-1)F_3^3} \sum_{k=k_1}^{k_2} (U(k) - \bar{U})^3$
5	谐波总畸变率	$F_5 = \frac{\sqrt{\sum_{n=2}^{36} U_n^2}}{U_d}$

2 基于 PDT-SVM 的暂降类型辨识

基于上述特征指标,提取每个暂降样本的特征向量,以作为暂降分类器的输入数据。文中采用基于 PDT-SVM 分类算法,克服了传统支持向量机多分类方法存在的不可分区域和误差积累现象,提高了分类的准确率。

2.1 支持向量机原理

支持向量机(support vector machine, SVM)是基于统计学习理论的一种机器学习方法,通过寻求结构化风险最小来提高学习机泛化能力,实现经验风险和置信范围的最小化,适合处理电压暂降这类样本特征维数较多的非线性数据分类问题,具有较好的泛化能力^[14-15]。图3为SVM分类基本原理。




图3 SVM分类原理

Fig.3 SVM classification theory

$w\mathbf{x}+b=0$ 为最优分类超平面,离超平面最近的2个样本向量被称为支持向量,两类支持向量与最优超平面间距之和为 $1/\|w\|$,因此最优超平面的求取问题就转化为优化问题,如式(1)所示。

$$\begin{cases} \min_{w,b} \frac{1}{2} \|w\|^2 \\ \text{s.t. } y_i(w\mathbf{x}_i+b) \geq 1 \quad i=1,2,\dots,l \end{cases} \quad (1)$$

其中,约束条件是指各个分类的样本向量距离超平面的距离要大于或者等于1。对于电压暂降这类复杂的分类问题来说,训练集中的实际样本向量是线性不可分的。因此需要引入松弛变量 ξ 和惩罚因子 C 来平衡样本分类精确度和算法复杂度之间的问题^[16]。此时,目标函数变为:

$$\begin{cases} \min_{w,b} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l \xi_i \\ \text{s.t. } y_i(w\mathbf{x}_i+b) \geq 1-\xi_i \quad i=1,2,\dots,l \end{cases} \quad (2)$$

利用拉格朗日乘法对上述问题进行求解后得到优化目标函数为:

$$\begin{cases} \max L = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j \\ \text{s.t. } \sum_{i=1}^l \alpha_i y_i = 0 \quad 0 \leq \alpha_i \leq C \end{cases} \quad (3)$$

其中, α_i 为拉格朗日乘子。当处理非线性问题时,通过引入核函数,将样本数据由低维向高维之间转换,则优化目标函数可以整合为:

$$\max L = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j K(\mathbf{x}_i, \mathbf{x}_j) \quad (4)$$

$$K(\mathbf{x}_i, \mathbf{x}_j) = \varphi(\mathbf{x}_i)^T \varphi(\mathbf{x}_j) \quad (5)$$

式中: $\varphi(\mathbf{x})$ 为低维空间向高维空间的映射。

2.2 决策树 SVM

决策树 SVM(decision tree support vector machine, DT-SVM)是决策树思想与 SVM 方法的结合。首先将实际样本数据做 SVM 二分类,每个子类在下一层继续划分为2个次子类,如此循环,直至生成叶子节点,即只包含一个单独类的节点^[17]。与 SVM 一对一,一对多分类方法相比具有以下优势^[18]: (1) DT-SVM 不存在不可分区域,分类正确率也较高;(2) 在进行 M 分类问题时,只需要构造 $M-1$ 个分类器;(3) 从上至下每一层次所需的训练样本及支持向量的数量递减,缩短了训练时间;(4) 分类时不必遍历所有分类器,缩短了分类时间。

其主要的缺点在于误差累积问题,如果在某个节点上发生分类错误,则错误会向下分支延续,最终导致叶子节点的分类结果与实际情况相差甚远。

2.3 基于 PDT-SVM 分类算法

为了解决误差积累问题,文中采用 PDT-SVM 方法,在分类过程中尽量保证每次二分类结果近似最优,生成二叉决策树结构。最终依据该结构来训练子分类器,PDT-SVM 算法流程如下,该方法是在 SVM 训练前针对每个子节点进行的二分类划分,确定各个 SVM 子分类器对应的位置以及训练样本。

步骤一:将电压暂降训练样本特征矩阵作为初始根节点,在根节点处调用粒子群聚类算法(particle swarm clustering optimization, POS),将样本划分为两类,形成2个子节点;

步骤二:判断子节点是否是包含一个类,若是转向步骤四,若不是则转向步骤三;

步骤三:对该子节点继续调用 PSO 算法,将其再划分为2个子节点,转向步骤二;

步骤四:若该节点为叶子节点,算法结束。

PSO 算法的思想是将聚类视为一种优化问题,在全局范围内利用 PSO 算法得到一个近似最优划分^[19]。每一个粒子包含数据中各个类簇中心的信息,粒子 \mathbf{X}_i 可表示为 $\mathbf{X}_i = (C_{i1}, C_{i2}, \dots, C_{ij})$,其中 C_{ij} 代表第 i 个粒子的第 j 类中心点坐标向量,粒子群 X 代表可能候选分类方案集合。对分类方案的优劣进行评价是应用优化算法进行聚类的关键,因此引入粒子评价的适应度函数 f 。在聚类分析中,最优的聚类结果应保证各个样本元素之间类内距离足够小且类间距离足够大,因此适应度函数为:

$$\begin{cases} f(\mathbf{X}_i) = w_1 \bar{d}_{\max}(\mathbf{X}_i) / w_2 \bar{d}_{\min}(\mathbf{X}_i) \\ \bar{d}_{\max}(\mathbf{X}_i) = \max_{j=1,2,\dots,k} \left\{ \sum_{\mathbf{x} \in C_{ij}} \frac{d(\mathbf{x}, C_{ij})}{|C_{ij}|} \right\} \\ \bar{d}_{\min}(\mathbf{X}_i) = \min_{\forall l,p,l \neq p} \{d(C_{il}, C_{ip})\} \end{cases} \quad (6)$$

式中: w_1, w_2 为设定的正常数; $\bar{d}_{\max}(\mathbf{X}_i)$ 为 \mathbf{X}_i 对应分类的最大的类内平均距离; \mathbf{x} 为样本向量; $d(\mathbf{x}, \mathbf{C}_{ij})$ 为标本向量与聚合类 \mathbf{C}_{ij} 中元素的距离; $|\mathbf{C}_{ij}|$ 为聚合类 \mathbf{C}_{ij} 中元素的个数; k 为暂降样本所分类簇的个数; $\bar{d}_{\min}(\mathbf{X}_i)$ 为 \mathbf{X}_i 对应分类的最小的类间距离。这样,通过搜索 f 的最小值,可以使暂降样本的分类结果同时满足类内距离最小和类间距离最大的原则。

由于 PSO 算法存在早熟收敛现象,有可能陷入局部最优解,所以文中算法在迭代中使每个粒子存在 20% 的几率变异为随机粒子,实现全局寻优。PSO 算法流程描述如下。

步骤一:随机确定初始化 \mathbf{X}_i 的速度和位置(聚类中心);

步骤二:按照最邻近法则对数据进行划分,依照适应度的计算公式,计算每个粒子的适应度值,更新个体极值;

步骤三: \mathbf{X}_i 存在 20% 的可能性变异为随机粒子,并寻找全局极值和全局极值位置;

步骤四:按 PSO 算法的位置公式和速度公式更新粒子的位置及速度;

步骤五:若达到结束条件,输出最优粒子的位置即最优的 2 个聚类中心;若未达到结束条件,则返回步骤二。

综上所述,暂降源类型辨识的实现步骤流程图如图 4 所示。

文中首先进行样本特征向量的计算,将暂降监测样本按照特征值计算方法计算特征向量(如表 2 所示),每个样本数据由包含 5 个特征值的列向量组成。然后调用 PSO 优化算法对每个节点处样本进行最优二分类划分,一直到只包含一种暂降类型数据为止。对于每个节点,以最优二分类样本数据作为二分类节点 SVM 分类器的训练数据,训练 PDT-SVM 分类模型。最后以此作为暂降类型辨识的分类器。

3 算例分析

文中选取我国某大型城市的暂降监测系统上传电压数据为分析样本。一共 115 个样本数据,其中包括故障暂降 55 个,雷击暂降 20 个,感应电机启动 20 个,变压器投切 20 个,训练数据与测试数据的分配比例如表 3 所示。

样本特征向量仅以暂降最低相的计算结果为准,部分样本数据特征计算结果如表 4 所示。

PSO 算法的适应度函数参数 w_1, w_2 分别取 0.2 和 0.6,优化迭代次数为 50,经过训练后的 PDT-SVM

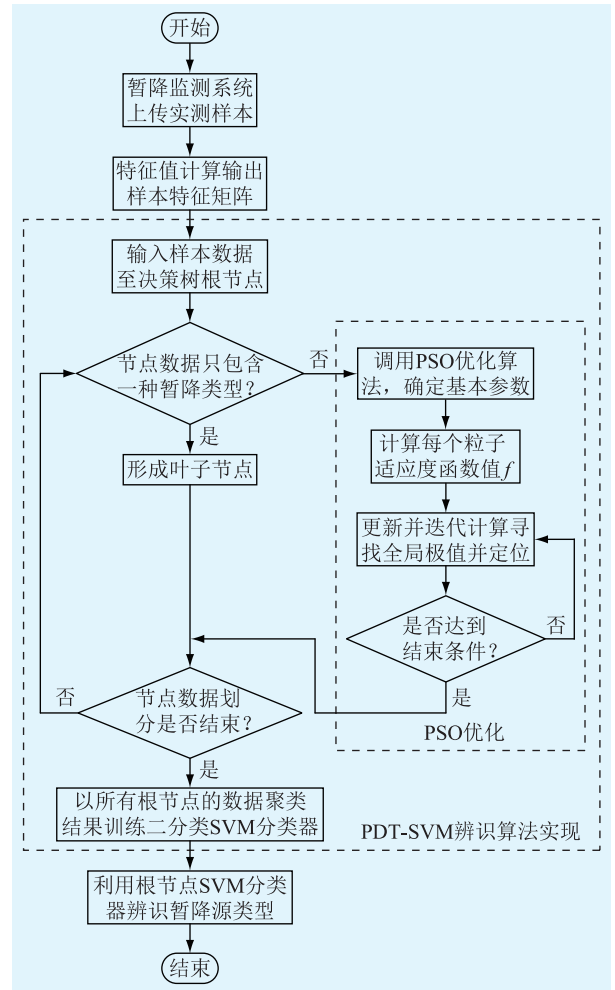


图 4 暂降源辨识步骤

Fig.4 Steps for voltage sag source identification

表 3 数据分配比例

暂降类型	训练样本	测试样本
变压器投切	15	5
短路故障	40	15
雷击	15	5
感应电机启动	15	5
总计	85	30

决策树结构共包含 7 个节点,其中有 3 个为根节点,4 个叶子节点。对测试样本的分类结果如图 5 所示,为 30 个测试样本的分类结果,正确分类事件 27 个,错误分类事件 3 个(1 组变压器投切,1 组两相短路故障,1 组单相短路故障)。分类正确率达到了 90%。

随后分别采用 DT-SVM 和多分类 SVM 以及所提方法对所有 115 条暂降样本数据进行了分类试验。试验结果如表 5 所示。

由表 5 可知,文中所提方法的分类正确率最高,但训练计算时间为 3 种方法中最长,这是由于引入

表4 样本数据
Table 4 Sample data

暂降类型	特征值结算结果				
	F_1	F_2	F_3	F_4	F_5
变压器投切	0.916 9	1.045 0	0.637 6	0.804 9	0.185 8
	0.799 2	1.007 4	0.646 6	0.709 8	0.181 3
故障	0.554 9	3.426 5	0.189 9	2.522 5	0.014 2
	0.542 4	2.741 1	0.373 4	4.122 7	0.015 8
雷击	0.780 1	1.027 9	0.633 7	0.772 1	0.290 8
	0.770 9	1.007 3	0.661 4	0.987 7	0.334 2
感应电机启动	0.616 7	1.041 7	0.618 4	0.845 9	0.010 7
	0.590 5	1.037 7	0.619 2	0.890 5	0.016 6




图5 测试样本辨识结果

Fig.5 Test sample identification results

表5 试验结果对比情况
Table 5 Comparison of test results

分类方法	正确分类个数	错误分类个数	分类正确率/%	训练所用时间/s	分类时间/s
DT-SVM	101	14	87.8	23.5	6.4
多分类-SVM	96	19	83.5	15.6	6.6
文中方法	112	3	97.4	27.7	6.8

PSO 优化后延长了分类器的训练时间,但在实际应用中,分类器的训练过程是离线完成的,并不影响实时分类的时间,以离线过程的计算时间代价来换取更准确的分类器性能是值得的。

4 结语

针对配电网雷击频发导致电压暂降的问题,基于暂降监测系统实测数据,对雷击故障导致电压暂降的情况进行了详细分析。文中总结分析了雷击故障导致暂降的波形特点,针对包含雷击在内的4种暂降类型波形特征提出了5个暂降波形特征指标;设计了基于PDT-SVM的暂降源辨识分类器,并利用电网暂降终端实际监测数据对算法有效性进行了验证;暂降分类正确率可达90%以上,并与其他分类器性能进行了对比,结果表明所提分类算法性能更优。

本文得到了国网江苏省电力有限公司总部科技项目(11-J2018029)资助,谨此致谢!

参考文献:

- [1] 徐鸣一,王振会,樊荣,等.江苏省地闪密度及雷电流幅值分布[J].南京信息工程大学学报(自然科学版),2010,2(6):557-561.
XU Mingyi, WANG Zhenhui, FAN Rong, et al. Distribution of lightning density and lightning current amplitude in Jiangsu Province[J]. Journal of Nanjing University of Information Science & Technology, 2010, 2(6):557-561.
- [2] 冯民学,韦海容,焦雪,等.江苏省雷电分布特征分析[J].气象科学,2009,29(2):246-251.
FENG Minxue, WEI Hairong, JIAO Xue, et al. Analysis of the lightning distribution features in Jiangsu Province[J]. Scientia Meteorologica Sinica, 2009, 29(2):246-251.
- [3] 徐伟,路永玲,唐梦颖,等.江苏电网近年雷电活动及输电线路雷击跳闸分析[J].电力工程技术,2017,36(6):106-110.
XU Wei, LU Yongling, TANG Mengying, et al. Analysis of lightning activities and transmission line lightning strike tripping in Jiangsu power grid in recent years[J]. Electric Power Engineering Technology, 2017, 36(6):106-110.
- [4] 路永玲,周志成,陶风波,等.江苏电网2014年输电线路雷击跳闸分析[J].江苏电机工程,2015,34(5):9-11.
LU Yongling, ZHOU Zhicheng, TAO Fengbo, et al. Analysis on the transmission line lightning tripping in the Jiangsu power grid in 2014[J]. Jiangsu Electrical Engineering, 2015, 34(5):9-11.
- [5] 杨家莉,徐永海.基于组合赋权与TOPSIS模型的节点电压暂降严重程度综合评估方法[J].电力系统保护与控制,2017,45(18):88-95.
YANG Jiali, XU Yonghai. Comprehensive evaluation method of node voltage sag severity based on combined weighting and TOPSIS model[J]. Power System Protection and Control, 2017, 45(18):88-95.
- [6] 司学振,李琼林,杨家莉,等.基于实测数据的电压暂降特性分析[J].电力自动化设备,2017,37(12):144-149.
SI Xuezhen, LI Qionglin, YANG Jiali, et al. Analysis of voltage sag characteristics based on measured data[J]. Electric Power Automation Equipment, 2017, 37(12):144-149.
- [7] 丁宁,蔡维,锁娟,等.电压暂降源识别方法研究[J].电网技术,2008,32(S2):55-59.
DING Ning, CAI Wei, SUO Juan, et al. Research on voltage sag sources recognition method[J]. Power System Technology, 2008, 32(S2):55-59.
- [8] 吕干云,方奇品,蔡秀珊.基于多分类支持向量机的电压暂降源识别[J].电力系统保护与控制,2010,38(22):151-155.
LYU Ganyun, FANG Qiping, CAI Xiushan. Identification of voltage sags source based on multi-class support vector machine[J]. Power System Protection and Control, 2010, 38(22):151-155.
- [9] 肖先勇,崔灿,汪洋,等.电压暂降分类特征可比性、相关性及马氏距离分类法[J].中国电机工程学报,2015,35(6):

- 1299-1305.
- XIAO Xianyong, CUI can, WANG yang, et al. Comparability and relevance of voltage sag classifying features and classification methods based on Mahalanobis distance[J]. Proceedings of the CSEE, 2015, 35(6):1299-1305.
- [10] 张宸宇, 史明明, 范忠, 等. 电压暂降事件分类及短路类型识别研究[J]. 电力工程技术, 2018, 37(2):102-107,113.
- ZHANG Chenyu, SHI Mingming, FAN Zhong, et al. Research on voltage sag event classification and short circuit type identification[J]. Electric Power Engineering Technology, 2018, 37(2):102-107,113.
- [11] 郑志宇, 李雅倩, 谢雪景, 等. 基于全寿命周期成本的电压暂降治理设备综合配置规划[J]. 电力系统保护与控制, 2018, 46(18):128-134.
- ZHENG Zhiyu, LI Yaqian, XIE Xuejing, et al. Integrated configuration planning of voltage sag control equipment based on life cycle cost [J]. Power System Protection and Control, 2018, 46(18):128-134.
- [12] 叶海峰, 谈发力, 吴昊, 等. 多重雷击导致变电站重合闸失败原因分析[J]. 水电能源科学, 2017, 35(9):173-176.
- YE Haifeng, TAN Fali, WU Hao, et al. Analysis of reclosing failure of substation caused by multiple lightning strikes[J]. Water Resources & Power, 2017, 35(9):173-176.
- [13] 马义, 张钰金, 钱苗旺, 等. 智能变电站与传统变电站若干关键技术比较[J]. 电力工程技术, 2016, 35(6):77-78,91.
- MA Yi, ZHANG Juejin, QIAN Miaowang, et al. Comparison between smart substation and traditional substation[J]. Electric Power Engineering Technology, 2016, 35(6):77-78,91.
- [14] JOACHIMS T. Making large-scale SVM learning practical[J]. Technical Reports, 1998, 8(3):499-526.
- [15] 李燕青, 袁燕舞, 郭通. 基于 AMD-ICSA-SVM 的超短期风电功率组合预测[J]. 电力系统保护与控制, 2017, 45(14):113-120.
- LI Yanqing, YUAN Yanwu, GUO Tong. Ultra-short term wind power combination forecasting based on AMD-ICSA-SVM [J]. Power System Protection and Control, 2017, 45(14):113-120.
- [16] CHANG K W, HSIEH C J, LIN C J. Coordinate descent method for large-scale L2-loss linear support vector machines[J]. Journal of Machine Learning Research, 2008, 9(3):1369-1398.
- [17] MADZAROV G, GJORGJEVIKJ D, CHORBEV I. A multi-class SVM classifier utilizing binary decision tree[J]. Informatica, 2009, 33(2):225-233.
- [18] HSU C W, LIN C J. A comparison of methods for multiclass support vector machines[J]. IEEE Transactions on Neural Networks, 2002, 13(4):1026.
- [19] MERWE D W V D, ENGELBRECHT A P. Data clustering using particle swarm optimization [C] // Evolutionary Computation, 2003. CEC'03. The 2003 Congress on. IEEE, 2004: 215-220.

作者简介:



李陶然

李陶然(1996),男,硕士在读,研究方向为电力系统及其自动化(E-mail:495715426@qq.com);

张宸宇(1989),男,博士,高级工程师,从事电能质量相关工作;

史明明(1986),男,博士,高级工程师,从事电能质量相关工作。

PDT-SVM-based sag source identification considering lightning strike

LI Taoran¹, ZHANG Chenyu², SHI Mingming², SHA Haoyuan¹, ZHENG Jianyong¹, MEI Fei³

(1. School of Electrical Engineering, Southeast University, Nanjing 210096, China;

2. State Grid Jiangsu Electric Power Co., Ltd. Research Institute, Nanjing 211103, China;

3. College of Energy and Electrical Engineering, Hohai University, Nanjing 210098, China)

Abstract: At present, voltage sag has become one of the most prominent power quality problems. In order to effectively analyze the impact of lightning stroke on power grid sag, the situation of voltage sag caused by lightning stroke is analyzed in detail. Four types of temporary relief, including lightning induced temporary relief, are identified accurately, which provides an important basis for the rational division of temporary relief liability. Firstly, the difference between the effective waveform of temporary sag caused by lightning stroke fault and the common short circuit fault is analyzed. The characteristics of RMS waveforms of four kinds of sag types, short circuit fault, lightning stroke, transformer switching and induction motor starting, are summarized. Five characteristic indices of sag voltage are introduced and the characteristic matrix of sag type identification is established. Then four types of sags are identified by using decision tree support vector machine (PDT-SVM) classifier based on particle swarm optimization. The training and testing data of the classifier come from the measured sag voltage data of the power grid, which is closely in line with the engineering practice. Finally, the validity and accuracy of the algorithm are verified by the analysis results of an example.

Keywords: lightning strike; voltage sag; root mean square value; characteristic identification; PDT-SVM

(编辑 钱悦)