

具有增量学习能力的智能孤岛检测方法

张沛超¹, 陈琪蕾¹, 李仲青², 杨珮鑫¹

(1. 上海交通大学 电气工程系 电力传输与功率变换控制教育部重点实验室, 上海 200240;

2. 中国电力科学研究院, 北京 100192)

摘要:基于机器学习的智能孤岛检测方法能有效地提高防孤岛保护的性能,但现有方法皆采用离线学习方案,对配电网因运行条件变化而导致的概念漂移现象缺乏自适应性。提出了一种具有在线增量学习能力的孤岛检测方法。首先,提出利用保护自采数据以及数据采集与监视控制(SCADA)系统采集的开关状态构成原始样本,并基于增量聚类方法进行样本筛选,实现有效样本的在线积累;然后,以各子样本集对系统最新状况的分类性能作为竞争准则,提出了一种样本集的优选方法,并利用加权支持向量机完成了增量学习。仿真结果表明,所提方法能够自主探测概念漂移的发生并进行持续的学习,有效地提高了孤岛检测的准确性和自适应性。

关键词:孤岛检测;概念漂移;聚类;增量学习;分布式发电;支持向量机

中图分类号:TM 76

文献标识码:A

DOI:10.16081/j.issn.1006-6047.2018.05.012

0 引言

分布式发电 DG (Distributed Generation) 广泛接入配电网是智能电网的核心特征之一。出于安全和电能质量等考虑,目前国内外并网标准都要求 DG 具备孤岛检测功能^[1]。常规孤岛检测方法包括被动检测^[2-4]、主动检测^[5-6]和基于通信的联跳^[7]。虽然主动检测法和联跳在提高检测速度和减少盲区方面具有优势,但被动检测法在经济性和不影响电能质量方面仍具有独特和突出的优势,且不存在主动检测法的多机并网逆变器间的相互影响问题^[8-9]。此外,被动检测法无有源扰动和无通道的特点符合保护追求的一贯目标。所以,被动检测依然是非常重要的防孤岛保护方案。即使在配置了主动检测或联跳方案的场合,被动检测法也应作为后备方案^[7]。

但是,被动检测法的主要缺陷在于存在较大的检测盲区,尤其当功率不平衡度较低时^[1,4,5,7]。同时,DG 的容量和类型、并网变压器的接线方式、功率不平衡度等诸多因素都会影响孤岛检测,这使得该方法很难整定^[10]。为了解决这些难题,近年来基于决策树^[11-14]、支持向量机 SVM (Support Vector Machine)^[15-17]以及神经网络^[18]等机器学习算法构成的智能孤岛检测方法受到了重视。较之文献[2-4]中的常规方法,新方法不再拘泥于传统继电器的概念,能够组合多个特征,并基于结构风险最小化等原理构建最佳分类器^[19],显著提升了常规被动检测方法的性能。

但是,上述智能孤岛检测方法^[11-18]存在一个共

性问题,即学习是离线完成的,所生成的孤岛检测模型是静态的。随着主动配电网技术的发展,配电网运行的确定性较之传统配电网将不断降低。一方面,配电网中 DG 渗透率的逐渐增大,会不断影响配电网内的功率不平衡度,并导致与主网的交换功率呈现波动性。另一方面,为了更好地接纳 DG 以及提高经济性与可靠性,配电网会进行动态重构。上述因素都会导致离线获得的孤岛检测模型因环境改变而造成准确度逐渐下降。这种现象在机器学习中被称作概念漂移^[19-21]。

从信息物理系统视角,在上述问题中,属于信息系统的保护单元因采用预置的模型而难以适应物理系统的不确定性。为此,本文提出了一种具有在线增量学习能力的智能孤岛检测方法。该方法实质上是将运行中的物理配电网当作一个精确的“交流计算台”,由信息系统对其持续采样并在线提取训练样本,然后通过增量学习保持对物理系统的适应性。

1 系统结构

本文方法由图1所示的双闭环系统构成。先利用离线训练模型构成初始的防孤岛保护,如图1下方的闭环系统,这即为现有的离线学习方案^[11-18];然后在系统运行时由上方的闭环系统进行增量学习,在发现概念漂移后自动更新孤岛检测模型,实现自适应保护,这即为本文的研究内容。

上述防孤岛保护与增量学习模块运行于独立的 CPU,从而不影响孤岛检测的实时性。由于用于孤岛检测的特征值与用于增量学习的特征值是一致的,故在线学习并不会额外增加防孤岛保护的计算量。

在防孤岛保护中设置2个检测模型区,分别用于当前运行和增量学习。待学习结束后,通过切换

收稿日期:2017-06-26;修回日期:2018-02-14

基金项目:国家重点研发计划项目(2017YFB0903000)

Project supported by the National Key Research and Development Program of China(2017YFB0903000)




图1 具有增量学习能力的孤岛检测信息物理系统

Fig.1 Cyber-physical system of islanding detection with incremental learning capability

检测模型区实现保护升级。上述检测模型可视为常规保护的定值，而检测模型切换类似于保护定值区切换。这种通过在线切换定值区实现自适应保护的方法已在实践中得到应用^[22]。

由图1可见，本文方法对防孤岛保护采用的特征值和分类器皆无特殊要求。鉴于现有文献已对孤岛检测中的特征选择^[15-16]、分类器^[11-18]问题做了较多研究，本文将聚焦于解决如下关键问题：①自动获取并筛选训练样本；②增量学习。下文将分别讨论。

2 训练样本的自动生成方法

2.1 原始样本获取

数字式防孤岛保护能在内存中记忆一段时间的特征值数据，其时间分辨率一般为保护采样周期，如1 ms。此外，配电网配置的数据采集与监视控制（SCADA）系统可以在线采集重要开关的状态。以上为实现自学习奠定了基础。

设 $E = \{(\mathbf{x}_i, y_i)\} (i = 1, 2, \dots, n)$ 为含 n 个实例的样本集。其中， $\mathbf{x}_i \in \mathbf{R}^d$ 为特征向量，可直接从保护内存中读取； $y_i \in \{1, -1\}$ 为分类标签（为1时表示孤岛），需根据关键开关状态判断。传送开关状态的SCADA报文中皆含有时间戳，其时间精度一般为1 ms。利用该时间戳可保证 $\mathbf{x}_i$ 与 y_i 取自同一时间截面。

SCADA系统以2种方式报告开关状态：一种是每隔1~2 s的周期性上送，另一种由模拟量越限或开关变位等事件触发上送。两者相结合可使在线学习系统不错过重要样本，如配电网中因电源或负荷波动等导致的扰动事件，以及因检修、网络重构、故障跳闸等原因导致的开关变位事件。

由图1可见，仅关键开关的位置信息需要从远方采集，其余信息皆能从本地获得。虽然本文方法

在学习环节需要远方通信，但与需要实时开关状态的联跳方法存在本质差别。后者需在关键开关和防孤岛保护之间建立实时性和可靠性达到保护级别的通信网，而本文方法只需利用既有SCADA通信网。由于报文自带时间戳，且概念漂移过程相对缓慢，所以本文方法对通信实时性和带宽的要求很低。在通信完全中断的极端情况下，图1上方的在线学习环断开，则本文方法至多退化为文献[11-18]中的方法。而一旦通信恢复，本文方法能保证恢复增量学习过程。

2.2 基于在线聚类的样本筛选方法

配电网正常运行时会产生大量冗余样本，导致样本分布严重失衡，影响学习效果。为了解决这个问题，本文提出一种基于聚类的样本筛选方法。

设簇 C 包含 n 个 d 维的样本 $\mathbf{X}_i = (x_i^1, x_i^2, \dots, x_i^d)$ ，其时间戳为 $T_i (i = 1, 2, \dots, n)$ 。将簇 C 视为 d 维的超球体，则其质心 $\mathbf{C}_C$ 定义为：

$$\mathbf{C}_C = \mathbf{F}/n \quad (1)$$

其中， $\mathbf{F} \in \mathbf{R}^d$ 为由样本各特征项代数和构成的向量，

其第 p 项为 $\sum_{i=1}^n x_i^p (p = 1, 2, \dots, d)$ 。

定义簇 C 的边界为 $\tau \times \sigma_C$ ，其中 $\tau > 0$ 为距离因子， σ_C 为簇中各点到质心 $\mathbf{C}_C$ 欧氏距离的标准差。

为了衡量簇 C 中样本的总体新旧程度，定义 $T_C = \sum_{i=1}^n T_i$ 为各样本的时间戳的代数和。

基于以上定义，下面结合图2说明本文方法的过程。

步骤1：初始化。首先将离线仿真时形成的初始样本集聚类为 Q 个初始簇，记为 $\mathbf{C}_q (q = 1, 2, \dots, Q)$ 。

步骤2：在线运行时，设在 T_i 时刻采集到新样本 $\mathbf{X}_i$ ，计算 $\mathbf{X}_i$ 与各簇 $\mathbf{C}_q$ 的质心 $\mathbf{C}_{C_q}$ 的归一化距离，如




图2 基于聚类的样本筛选方法

Fig.2 Sample selection method based on clustering

式(2)所示。

$$\lambda_q = \frac{\|X_i - C_{C_q}\|^2}{\tau \times \sigma_{C_q}} \quad q=1,2,\dots,Q \quad (2)$$

设新样本 X_i 与簇 $C_j (j=1,2,\dots,Q)$ 的距离 λ_j 最小。执行如下规则:

a. 若 $\lambda_j \leq 1$, 则新样本 X_i 被簇 C_j 吸收而不被选为后续训练样本, 如图2中的样本 X_1 和 X_2 ;

b. 如果 $\lambda_q > 1 (\forall q)$, 表明新样本 X_i 距所有簇都超过其最大边界, 则将 X_i 保留为新的训练样本, 同时以 X_i 创建新簇, 如图2中的样本 X_3 ;

c. 为了保持簇的总数为 Q , 找出 T_c 值最小的簇 (距今平均时间最长), 将其遗忘, 如图2中的簇 C_n 。

最终, 只有样本 X_3 被选入训练集中, 用于后续机器学习, 而原始样本 X_1 和 X_2 作为冗余样本被丢弃。

在线采集的原始样本具有无限长的数据流特征, 无法进行批处理聚类。为此, 本文利用簇的伴随向量^[23]实现了增量聚类, 使得本文算法适合在线进行。

利用以上形成的带有分类标签的样本集即可进行机器学习。为了使学习过程能自适应于概念漂移的发生, 本文提出了一种在线增量学习方法。

3 增量学习方法

增量学习的主要挑战在于所谓的“稳定性-可塑性困境”^[20]。过于稳定的学习算法能够很好地保留现有知识, 但学习新知识的能力差; 反之, 可塑能力过强的算法虽能立即学习新知识, 但却难以稳定保存已学到的知识, 甚至无法收敛。本文提出一种优选样本集方法, 兼顾了增量学习的“温故”与“知新”能力。

3.1 优选样本集方法

常用的增量学习方法主要有滑动数据窗和多分类器集成^[21]。其中, 前者单纯以时间作为评价样本是否有用的条件, 容易逐渐丢失有用的样本, 保存之前有用知识的能力较差; 而后者需将样本集切分为多个子集以构成多个子分类器, 然后通过多分类器加权的方法进行集成, 以提高分类器的泛化能力, 但这样容易加剧样本的非均衡性, 导致算法的稳定性不足。

本文提出的优选样本集方法如图3所示。设训练样本集被均分为 k 个子集, 相应生成 k 个子分类器 M_1-M_k 。则后续增量学习包含如下阶段。

a. 先将由第2节聚类方法得到的新样本加入子集 $k+1$ 中, 当其样本数达到要求后触发增量学习, 采用10折交叉验证^[19]完成训练与测试, 生成子分类器 M_{k+1} 。这样就存在 $k+1$ 个子分类器, 需进行优胜劣汰。




图3 优选样本集增量学习方法

Fig.3 Incremental learning method based on optimal sample sets

b. 以最新样本集 (即子集 $k+1$) 对所有子分类器 $M_1, M_2, \dots, M_{k+1}$ 进行测试, 得到的分类错误率分别为 $\omega_1, \omega_2, \dots, \omega_{k+1}$ 。淘汰错误率最高的子集, 将剩余的 k 个子集合并为一个样本集, 即优选样本集。

c. 利用优选样本集, 经在线训练生成新的孤岛检测分类器模型, 完成在线自学习。

与滑动数据窗方法相比, 本文方法基于竞争而非单纯时间因素淘汰样本, “知新”的同时也注意“温故”; 与多分类器集成方法相比, 本文方法由于优选样本集中样本数大于各子集, 能够有效地改善样本的均衡性, 提高了抗干扰性。仿真结果表明, 本文方法具有更好的稳定性。

3.2 加权 SVM 算法

本文提出的增量学习框架中可以采用各种分类算法, 如决策树^[11-14]、SVM^[15-17]等。但是由于样本分布存在非均衡性, 易使分类结果偏向多数类。文献[24]通过实验证明, 较之 C4.5 决策树和 BP 神经网络, 非均衡性对 SVM 算法的影响更小, 故本文选用 SVM 算法。SVM 算法可通过引入惩罚参数调节分类模型的泛化能力, 而加权 SVM 算法^[25]则通过对不同类别的样本赋予不同的惩罚参数, 进一步降低由于类别失衡带来的分类误差。加权 SVM 算法通过求解式(3)所示最优化问题得到最优分类面。

$$\begin{cases} \min_{\omega, b, \xi_i} \frac{1}{2} \|\omega\|^2 + C^+ \sum_{y_i=1} \xi_i + C^- \sum_{y_i=-1} \xi_i \\ \text{s.t. } y_i(\omega^T \phi(x_i) + b) \geq 1 - \xi_i \quad \xi_i > 0; i=1, 2, \dots, n \end{cases} \quad (3)$$

其中, ω, b 分别为分类超平面的法向量和截距; n 为样本数量; ξ_i 为松弛变量; $\phi(x_i)$ 为样本 x_i 在高维空间的映射; C^+ 和 C^- 分别对应孤岛和非孤岛误分类样本的惩罚参数。由于孤岛类样本比较少, 因此应有 $C^+ > C^-$, 即希望对少数类中误分类样本的惩罚更大, 以减小分类面的倾向性。本文取 $C^+ = lC^-$, 其中 l 为样本集中孤岛和非孤岛类样本数的比值。

本文采用径向基 (RBF) 核函数 $K(x_i, x) =$

$e^{-\gamma \|x-x_i\|^2}$ [15-17]。通过调节参数 γ 理论上可以实现任意数据的线性划分,但为了避免过拟合问题,需合理选择参数 γ 。这样在训练时待求参数只有 $\{\gamma, C^+\}$ 。为了求取上述参数,本文采用常用的网格搜索法 [19] 并结合了 5 折交叉验证。

4 算例

4.1 算例设计

本文采用与文献 [12-13] 相似的模型进行孤岛检测的训练和测试,如图 4 所示。系统包含 3 个 DG,其中 DG_1 处为光伏, DG_2 、 DG_3 为同步发电机。 DG_3 在仿真初始时(离线学习阶段)处于停运状态。本文以 DG_1 处光伏系统为研究对象,利用 PSCAD 仿真图 4 所示模型,详细参数设置见附录。根据文献 [12-13],本文以频率 f 、电压幅值 U 、电流幅值 I 、电压-电流相角差 φ 、有功功率 P 和无功功率 Q 这 6 个电气量构成特征向量。




图4 含多个 DG 的配电网络系统

Fig.4 Distribution network system with multiple DGs

表 1 列出了仿真中考虑的事件类型,包括断路器动作和负荷、电容器及其他 DG 投切事件等 [12-13]。将所考虑的孤岛事件记为 A_1 — A_3 ,非孤岛事件记为 B_1 — B_7 。为了模仿实际情况中非孤岛样本占比较高

表 1 与 DG_1 相关的仿真事件

Table 1 Simulation events related to DG_1

类型	开关动作	PI
孤岛事件	A_1 : cb_1 断开(大孤岛事件)	有功 PI 在 10%~90% 区间内变化 [4,16-17], 负荷存在 5% 范围内的随机波动
	A_2 : cb_3 断开	
	A_3 : cb_4 断开(小孤岛事件)	
非孤岛事件	B_1 : 负荷 L_1 退出,即 cb_2 断开	
	B_2 : 相邻线路退出,即 cb_9 断开	
	B_3 : DG_2 退出,即 cb_{11} 断开	
	B_4 : 本地负载 L_3 退出,即 cb_6 断开	
	B_5 : DG_3 投运	
	B_6 : 本地负载 L_3 处切除电容器	
	B_7 : 本地负载 L_3 处投入电容器	

的情形,仿真中将上述 2 类事件按照一定比例混合,然后做均匀随机抽样。在最终形成的样本中,孤岛样本数量约占 12%。

此外,功率不平衡度 PI (Power Imbalance) 对孤岛检测的分类准确率有很大的影响 [4,7,16-17]。有功 PI 的定义为:

$$p_{PI} = \frac{P_{SYS}}{P_{SYS} + P_{DG}} \times 100\% \quad (4)$$

其中, P_{SYS} 为主电网经公共耦合点 (cb_1 处) 输入配电网的有功功率; P_{DG} 为本地 DG 所发出的总有功功率。

4.2 增量学习过程

采用如下方案模拟概念漂移:初始时 DG_3 未投运, $p_{PI} = 90\%$, 然后使有功 PI 先逐渐降低再逐渐增大,并随机产生表 1 中的各类事件;系统每 2 s 采集原始样本,并基于聚类方法进行样本筛选,每获得 60 个样本构成一个子样本集;形成 13 个子样本集后, DG_3 投运。最终,得到了图 5 所示的 23 个子样本集 E_1 — E_{23} 。




图5 子样本集的事件分布

Fig.5 Distribution of events in subsample sets

先利用子集 E_1 经离线训练生成初始的孤岛检测模型。令图 3 中 $k=8$, 则从子集 E_9 开始,同时利用滑动数据窗、多分类器集成以及本文提出的优选样本集方法进行增量学习。这 3 种学习方法采用各自的淘汰机制完成新旧样本的更替,并更新分类器模型。

限于篇幅,下文仅给出优选样本集方法的子集在学习过程中的更替演化情况,如图 6 所示。图 6 中,初始时使用子集 E_1 — E_8 ;在第 1 次学习后,新增子集 E_9 、淘汰了子集 E_5 ;在第 2 次学习后,新增 E_{10} 并淘汰了 E_3 ;第 6 次学习时对应图 5 中 DG_3 投运事件。由图 6 可看出,新子集由于更能反映系统的当前状况,故被选中的概率更高,而旧子集被淘汰的可能性更大。但某些子集(如 E_{12} 、 E_{14})在竞争中表现良好,被保留较长时间。

需要说明的是,图 6 所示的分类器更新过程完全是由概念漂移触发的。如果配电网运行比较平稳,则系统很久才会触发一次增量学习;反之,如果概念漂移频繁发生,则学习过程也相应加快。




图6 增量学习过程中子样本集的更新过程

Fig.6 Update of subsample sets in incremental learning process

4.3 增量学习效果

将现有文献采用的离线分类器方法^[11-18]和3种在线分类器的性能进行对比,如表2和图7所示,其中,优选样本集方法分别采用了传统SVM和加权SVM这2种算法。对于非均衡分布的样本,传统的分类准确率指标会掩盖少数类样本的分类错误,故本文采用平衡精度BAC(Balanced ACcuracy)^[24]作为孤岛检测方法的评价指标:

$$BAC = (S_{\text{sensitivity}} + S_{\text{specificity}}) / 2 \quad (5)$$

其中, $S_{\text{sensitivity}}$ (敏感度)和 $S_{\text{specificity}}$ (特异度)分别为+1类样本和-1类样本的分类准确率。

首先分析现有文献所采用的离线分类器方法^[11-18]。该分类器采用子集 E_1 完成离线训练后即不再更新。由表2可见,其BAC几乎都低于85%,仅对子集 E_{22} 、 E_{23} 有较高的BAC。这是因为它们与 E_1 有相似的PI值(皆大于80%)。可见,离线分类器对PI值非常敏感,且很难适应概念漂移问题。

表2 各分类方法的BAC对比

Table 2 Comparison of BAC among various classification methods

分类器更新次数	测试样本集	BAC/%				
		现有方法(离线分类)	滑动数据窗	多分类器集成	传统SVM+优选样本集	加权SVM+优选样本集
1	E_9	72.00	100.00	73.00	100.00	100.00
2	E_{10}	50.65	84.69	50.00	100.00	100.00
3	E_{11}	47.12	100.00	82.65	100.00	100.00
4	E_{12}	48.96	87.50	100.00	87.50	100.00
5	E_{13}	49.00	80.00	85.00	80.00	95.00
6	E_{14}	46.10	68.18	68.18	68.18	68.18
7	E_{15}	57.79	63.64	72.73	63.64	63.64
8	E_{16}	48.04	66.67	66.67	66.67	83.33
9	E_{17}	47.92	66.67	83.33	83.33	83.33
10	E_{18}	46.10	68.18	81.82	81.82	95.46
11	E_{19}	83.33	66.67	50.00	83.33	83.33
12	E_{20}	81.82	68.18	50.00	86.36	100.00
13	E_{21}	81.50	50.00	50.00	100.00	97.20
14	E_{22}	90.00	50.00	50.00	81.82	100.00
15	E_{23}	92.90	50.00	50.00	100.00	100.00




图7 各种分类方法的BAC对比

Fig.7 Comparison of BAC among various classification methods

与之相比,在线学习分类器的性能普遍得到改善,尤其当PI较低时。但滑动数据窗和多分类器集成方法的BAC波动较大,尤其当PI恢复至较高值时,其BAC值甚至不如离线分类器,验证了这2类增量学习方法在稳定性与可塑性方面皆存在欠缺。

而本文提出的优选样本集方法显示了良好的稳定性和可塑性,BAC值总体保持稳定。虽然在第6次分类器更新时,因 DG_3 投运改变了配电网的运行方式,从而导致BAC下降,但通过自学习很快提升了分类精度。进一步对比加权SVM和传统SVM算法的分类结果,发现前者更有优势,原因是前者进一步减小了样本非均衡性的不利影响。

4.4 算法的实时性

仿真软件为MATLAB 2014a,仿真计算机的CPU主频为3.1 GHz,内存为4 GB。

因概念漂移发生较为缓慢,故本方法对增量学习无实时性要求。按照图3的流程完成新分类器的训练,实际耗时0.47 s。在实用中,可利用防孤岛保护的辅助CPU插件(如通信)完成增量学习。

而孤岛检测则有严格的实时性要求。但本文方法并未增加防孤岛保护的计算量,故保护的实时性与文献[11-18]的采用离线分类器的防孤岛保护相似。

5 结论

针对因配电网运行条件变化而导致的概念漂移现象,本文提出了一种具有在线增量学习能力的智能孤岛检测方法。首先,将实际配电网当作“交流计算台”,提出利用保护自采数据以及SCADA系统采集的开关状态生成原始样本,并利用增量聚类方法筛选样本以改善其均衡性;然后,提出一种基于优选样本集的增量学习方法,加强了学习的稳定性与可塑性,且学习过程由概念漂移的发生所驱动,具有自适应性。

在配电网的时变性和不确定性不断增强的背景下,本文方法的价值在于提高被动孤岛检测方法的

准确性和适应性。同时,本文中学习过程和孤岛检测是异步进行的,孤岛检测功能仍只需本地信息,不依赖于通信,这保证了方法的实时性、可靠性和经济性。

本文在线形成训练样本时,暂未考虑因 SCADA 所产生的坏样本的检测与剔除问题,对此问题有待做进一步的研究。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

- [1] 王继东,张小静,杜旭浩,等. 光伏发电与风力发电的并网技术标准[J]. 电力自动化设备,2011,31(11):1-7.
WANG Jidong, ZHANG Xiaojing, DU Xuhao, et al. Standards of grid-connection technology for photovoltaic and wind power generations[J]. Electric Power Automation Equipment, 2011, 31(11): 1-7.
- [2] 郑涛,王燕萍,袁飞,等. 基于工频突变量阻抗测量的新型孤岛检测方法[J]. 电力自动化设备,2016,36(5):8-13.
ZHENG Tao, WANG Yanping, YUAN Fei, et al. Islanding detection based on power-frequency variation impedance[J]. Electric Power Automation Equipment, 2016, 36(5): 8-13.
- [3] 王小立,温靖华,袁飞,等. 基于频率-功率因数角组合判据的新型孤岛检测法[J]. 电力系统保护与控制,2015,43(14):100-105.
WANG Xiaoli, WEN Jinghua, YUAN Fei, et al. A new anti-islanding detecting method based on combined criterion of frequency and power-factor angle[J]. Power System Protection and Control, 2015, 43(14): 100-105.
- [4] FREITAS W, XU W, AFFONSO C M, et al. Comparative analysis between ROCOF and vector surge relays for distributed generation applications[J]. IEEE Transactions on Power Delivery, 2005, 20(2):1315-1324.
- [5] 贺超,王冕,陈国柱. 基于下垂控制的孤岛检测方法及其改进策略[J]. 电力自动化设备,2015,35(6):87-92.
HE Chao, WANG Mian, CHEN Guozhu. Islanding detection based on droop control and its improvement strategy[J]. Electric Power Automation Equipment, 2015, 35(6): 87-92.
- [6] 王雪,雷胜华,胡文平,等. 基于自适应负序电压正反馈的孤岛检测方法[J]. 电力自动化设备,2016,36(12):36-42.
WANG Xue, LEI Shenghua, HU Wenping, et al. Islanding detection based on adaptive positive feedback of negative-sequence voltage[J]. Electric Power Automation Equipment, 2016, 36(12): 36-42.
- [7] 杨珮鑫,张沛超. 分布式电源并网保护研究综述[J]. 电网技术,2016,40(6):1888-1895.
YANG Peixin, ZHANG Peichao. A survey on interconnection protection of distributed resource[J]. Power System Technology, 2016, 40(6): 1888-1895.
- [8] 谢东,张兴. 主动移频式孤岛检测法产生稀释效应机理的分析[J]. 电力系统保护与控制,2013,41(4):84-90.
XIE Dong, ZHANG Xing. Analysis of dilution phenomenon for active frequency shift islanding detection method[J]. Power System Protection and Control, 2013, 41(4): 84-90.
- [9] 刘方锐,段善旭,康勇,等. 多机光伏并网逆变器的孤岛检测技术[J]. 电工技术学报,2010,25(1):167-171.
LIU Fangrui, DUAN Shanxu, KANG Yong, et al. Islanding detection methods for multiple PV converters system[J]. Transactions of China Electrotechnical Society, 2010, 25(1): 167-171.
- [10] MOZINA C J. Impact of smart grids and green power generation on distribution systems[J]. IEEE Transactions on Industry Applications, 2013, 49(3):1079-1090.
- [11] FAR H G, RODOLAKIS A J, JOOS G. Synchronous distributed generation islanding protection using intelligent relays[J]. IEEE Transactions on Smart Grid, 2012, 3(4):1695-1703.
- [12] EL-ARROUDI K, JOOS G. Data mining approach to threshold settings of islanding relays in distributed generation[J]. IEEE Transaction on Power System, 2007, 22(3):1112-1119.
- [13] EL-ARROUDI K, JOOS G, KAMWA I, et al. Intelligent-based approach to islanding detection in distributed generation[J]. IEEE Transactions on Power Delivery, 2007, 22(2):828-835.
- [14] SAMANTARAY S R, EL-ARROUDI K, JOOS G, et al. A fuzzy rule-based approach for islanding detection in distributed generation[J]. IEEE Transactions on Power Delivery, 2010, 25(3):1427-1433.
- [15] 朱艳伟,石新春,李鹏. 多分辨率奇异谱熵和支持向量机在孤岛与扰动识别中的应用[J]. 中国电机工程学报,2011,31(7):64-70.
ZHU Yanwei, SHI Xinchun, LI Peng. Classification of islanding and grid disturbance based on multi-resolution singular spectrum entropy and SVM[J]. Proceedings of the CSEE, 2011, 31(7): 64-70.
- [16] 张沛超,谭啸风,杨珮鑫. 孤岛检测的关键特征识别及元学习方法[J]. 电力系统自动化,2014,38(18):72-78.
ZHANG Peichao, TAN Xiaofeng, YANG Peixin. Critical feature identification and meta-learning method for islanding detection[J]. Automation of Electric Power Systems, 2014, 38(18): 72-78.
- [17] 杨珮鑫,张沛超. 基于多分类支持向量机的分布式发电系统并网保护[J]. 电力系统自动化,2015,39(22):110-116.
YANG Peixin, ZHANG Peichao. Distributed generation system interconnection protection based on multi-class SVM[J]. Automation of Electric Power Systems, 2015, 39(22): 110-116.
- [18] 谢东,张兴,曹仁贤. 基于小波变换与神经网络的孤岛检测技术[J]. 中国电机工程学报,2014,34(4):537-544.
XIE Dong, ZHANG Xing, CAO Renxian. Islanding detection based on wavelet transform and neural network[J]. Proceedings of the CSEE, 2014, 34(4): 537-544.
- [19] WITTEN I H, FRANK E, HALL M A, et al. Data mining: practical machine learning tools and techniques[M]. 3rd ed. [S.l.]: Morgan Kaufmann, 2011:152-159.
- [20] ELWELL R, POLIKAR R. Incremental learning of concept drift in nonstationary environments[J]. IEEE Transactions on Neural Networks, 2011, 22(10):1517-1531.
- [21] WANG H, FAN W, YU P S. Mining concept-drifting data streams using ensemble classifiers[C]// International Conference on Knowledge Discovery and Data Mining. Tianjin, China: IEEE, 2003:226-235.
- [22] LAAKSONEN H, ISHCENKO D, OUDALOV A. Adaptive protection and microgrid control design for Hailuotuo island[J]. IEEE Transactions on Smart Grid, 2014, 5(3):1486-1493.
- [23] AGGARWAL CC, HAN J, WANG J, et al. A framework for clustering evolving data streams[C]// International Conference on Very Large Data Bases. [S.l.]: VLDB Endowment, 2003:81-92.
- [24] JAPKOWICZ N, STEPHEN S. The class imbalance problem: a systematic study[J]. Intelligent Data Analysis, 2002, 6(5):429-449.
- [25] CHANG C C, LIN C J. LIBSVM: a library for support vector machines[J]. ACM Transactions on Intelligent Systems and Technology, 2011, 2(3):27.

作者简介:

张沛超(1970—),男,江苏连云港人,副教授,博士,主要研究方向为电力系统保护与控制、智能变电站和电力系统仿真(E-mail:pczhang@sjtu.edu.cn);

陈琪蕾(1994—),男,山西临汾人,硕士研究生,主要研究方向为电力系统保护与控制、电力系统仿真(E-mail:5628830cql@sjtu.edu.cn);



张沛超

李仲青(1978—),男,黑龙江鸡西人,高级工程师,硕士,主要研究方向为电力系统保护、动态仿真、智能变电站相关技术等;

杨珮鑫(1992—),女,陕西西安人,硕士,主要研究方向为电力系统保护、机器学习。

Intelligent islanding detection method with incremental learning capabilityZHANG Peichao¹, CHEN Qilei¹, LI Zhongqing², YANG Peixin¹

(1. Key Laboratory of Control of Power Transmission and Conversion, Department of Electrical Engineering, Shanghai Jiao Tong University, Shanghai 200240, China; 2. China Electric Power Research Institute, Beijing 100192, China)

Abstract: The machine learning-based intelligent islanding detection method can improve the performance of anti-islanding protection effectively. However, the existing methods are all based on the offline learning scenario, which can not adapt to the concept drifting phenomenon caused by the changes of operating condition in the distribution network. An islanding detection method with online incremental learning capability is proposed. Firstly, the primary samples are composed of the field data collected by protection devices and the switch states collected by the SCADA (Supervisory Control And Data Acquisition) system, and selected based on the incremental clustering method to accumulate the effective samples online. Then, an optimal selection method of sample set is proposed by taking the classification performance of each subsample set to the latest situation of the system as the competition rule, and the support vector machine is applied to realize the incremental learning. Simulative results show that, the proposed method can effectively improve the accuracy and adaptability of islanding detection by detecting the concept drift automatically and performing learning continuously.

Key words: islanding detection; concept drift; clustering; incremental learning; distributed power generation; support vector machines

附 录

a. 电源参数。

大电网为无穷大电源，容量为 $1000\text{MV}\cdot\text{A}$ ，额定电压为 69kV ，系统频率为 50Hz ，初始功角为 0° 。

DG_1 处为光伏电源系统，单台额定容量为 $1.67\text{MV}\cdot\text{A}$ ，每个接入点有 3 个相同的光伏系统经升压变压器并入电网。光伏变流器的控制模式采用 PQ 解耦控制。控制回路中包含限幅环节，最大短路电流被限制为 1.5 倍额定电流。

DG_2 、 DG_3 采用同步电机模型，具有自动电压控制功能，容量为 $5\text{MV}\cdot\text{A}$ ，额定电压为 13.8kV ，惯性常数为 3.0s ，零序电阻为 0.0027p.u. ，零序电抗为 0.113p.u. ，正序电阻为 0.001p.u. ，正序电抗为 0.15p.u. ，输出有功功率为 $0.1\sim 1\text{p.u.}$ 。

b. 变压器参数。

T_1 参数：连接方式为 Dyn1，额定容量为 $25\text{MV}\cdot\text{A}$ ，变比为 $69\text{kV}/13.8\text{kV}$ ，基准电压为 13.8kV ，绕组电阻为 0.00375p.u. ，绕组电抗为 0.01p.u. ，激磁电阻为 500p.u. ，激磁电抗为 500p.u. 。

T_2 、 T_3 、 T_4 参数：连接方式为 Ynd1，额定容量为 $10\text{MV}\cdot\text{A}$ ，变比为 $13.8\text{kV}/13.8\text{kV}$ ，基准电压为 13.8kV ，绕组电阻为 0.00375p.u. ，绕组电抗为 0.01p.u. ，激磁电阻为 500p.u. ，激磁电抗为 500p.u. 。

c. 输电线参数。

TL_1 — TL_5 ：额定电压为 13.8kV ， π 模型，零序电阻 $R_{0L}=0.0414\Omega/\text{km}$ ，正序电阻 $R_{1L}=0.0138\Omega/\text{km}$ ，零序电抗 $X_{0L}=0.0534\Omega/\text{km}$ ，正序电抗 $X_{1L}=0.0178\Omega/\text{km}$ ，零序电容 $C_{0L}=5.1\text{nF}/\text{km}$ ，正序电容 $C_{1L}=17\text{nF}/\text{km}$ 。