

基于TSVM模型的智能电能表自动化检定系统异常检测

庄葛巍¹, 顾臻¹, 冯秀庆², 段艳³

- (1. 国网上海市电力公司 电力科学研究院, 上海 200051;
2. 上海欣能信息科技发展有限公司, 上海 200025;
3. 同济大学 汽车学院, 上海 201804)

摘要: 智能电能表自动化检定系统在长期运行过程中可能出现异常,但定期人工检测方法无法及时获悉风险信息,缩短人工检查的周期又将降低自动化检定的工作效率。在多数情况下异常表位样本数据是无标记的,通常采用无监督异常检测算法筛选异常表位,为降低无监督异常检测的误报率,减少人工检查的代价,提出请求对无监督筛选的“异常表位”进行人工检查,在排除表位故障的同时获得少量标记样本,利用标记和无标记样本构建半监督方式直推式支持向量机(TSVM)异常检测模型,在以后的自动化检定工作过程中不断获取新的标记样本与未标记样本,可继续按照半监督训练方式对TSVM模型进行扩展及优化。使用提出的方法对国网上海市电力公司自动化检定数据进行了分析,对比人工检查结果,验证了方法的有效性。

关键词: 智能电能表; 自动化检定; 检定数据; 异常检测; 半监督; 直推式支持向量机模型

中图分类号: TP181 **文献标识码:** A **DOI:** 10.19457/j.1001-2095.dqcd23182

Anomaly Detection of Automatic Verification System for Smart Meter Based on TSVM Model

ZHUANG Gewei¹, GU Zhen¹, FENG Xiuqing², DUAN Yan³

- (1. *Electric Power Research Institute, State Grid Shanghai Electric Power Company, Shanghai 200051, China;*
- 2. Shanghai Xinneng Information and Technology Development Co., Ltd., Shanghai 200025, China;*
- 3. Automotive College, Tongji University, Shanghai 201804, China)*

Abstract: Automatic verification system of smart meter may be abnormal in the long-term operation process, but the regular manual detection method can not timely learn the risk information, shortening the period of manual inspection will reduce the work efficiency of automatic verification. In most cases, the sample data of abnormal epitopes are unmarked, and the unsupervised anomaly detection algorithm is usually used to screen abnormal epitopes. In order to reduce the false positive rate of unsupervised anomaly detection and the cost of manual inspection, a request for manual inspection of unsupervised screening "abnormal epitopes" was proposed, in the process of eliminating epitope faults, a small number of labeled samples were obtained, and semi-supervised transductive support vector machine (TSVM) anomaly detection model was constructed by using labeled and unlabeled samples. In the future automatic verification work process, new labeled samples and unlabeled samples were obtained continuously, the TSVM model could be extended and optimized according to semi-supervised training method. Using the proposed method, the automatic verification data of state grid Shanghai electric power company was analyzed, and compared with the manual inspection results, the effectiveness of the method was verified.

Key words: smart meter; automatic verification; verification data; anomaly detection; semi-supervised; TSVM model

电能表为电力交易中的贸易结算提供依据, 电能表检定工作的重要性日益凸显^[1-2]。随着智能电网的建设工作不断推进, 智能电能表的需求量正日益增长, 为应对激增的智能电能表检定工

作量,具有高检定效率的自动化检定系统应运而生^[3-5]。但智能电能表检定系统在长期不间断的运行过程中,接驳环节可能出现机械疲劳甚至老化,引起检定结果异常。目前,计量中心是在自动化检定系统所监控的流水线处于停运的状态下,定期开展人工检查,以确保各检定单元的准确运行状态,但该方法无法及时获悉自动化检定系统所监控的流水线相关的风险信息,使得检定系统在下一人工检查前仍将服务于试验项目,这将导致大规模试验结果出现偏差,虽然通过缩短人工检查的时间间隔,可以在一定程度上降低上述情况发生的可能性,但会大幅降低流水线的检定效率,同时增加人力和运维成本。实现对自动化检定系统上各检定表位接驳环节机械性能的在线评价,对于提升自动化检定系统的可靠性具有重要意义。

对于如何实现自动化检定系统的异常在线检测,已经有相关学者通过研究提出了一些解决方案。文献[6]针对自动化检定系统的流水线的故障特点,构建了基于模糊推理的故障诊断专家系统;文献[7]基于数据挖掘相关算法改进原理,建立故障征兆和故障性质的关联规则,实现对二次回路故障的实时诊断;文献[8]针对自动化检定系统的流水线设备检修频率缺乏科学性的问题,建立了基于检修优先级系数求解设备最佳检修频率的数学模型,为流水检修周期提供科学依据;文献[9]提出了一种自动化检定系统的流水线表位故障定位及报警系统,该系统通过识别连续检定不合格的表位来进行故障判定;文献[10]采用数据仓库技术(extract-transform-load, ETL)、用于过程控制的OLE(OLE for process control, OPC)等标准协议与技术,通过采集流水线风险信息并结合专家系统,实现对检定流水线的风险预警和对系统的评估;文献[11]采用局部异常检测算法对流水线检定表位异常进行故障识别。由于多数情况下异常数据是无标记的,异常检测研究多从无监督角度出发^[1],无监督异常检测方法适合数据量少、维度低的数据异常识别^[2],应用到数据量较大的智能电表检定流水线上,如何降低模型的误判率将是一个难题,虽然有监督异常检测算法的试验效果好,但模型的训练样本需要以大量的人工标记为代价,所以在自动化检定中适用性不强。

针对以上问题,提出利用自动化检定系统数

据,通过对无监督异常检测算法筛选的“异常表位”进行人工检查,能够在排除表位故障的同时获得少量标记样本,利用少量的标记样本和大量的无标记样本采用半监督方式构建直推式支持向量机(transductive support vector machine, TSVM)异常检测模型,TSVM模型可对未标记样本进行标记。流水线在工作过程中不断获取新的未标记样本,可继续按照半监督方式对TSVM模型进行扩展及优化。文中所提出的异常表位的检测算法利用国网上海市电力公司自动化检定系统数据进行了分析,通过对比人工检查结果,验证了方法的有效性,降低了无监督式异常检测算法的误判率,对自动化检定系统的运维智能化工作具有一定指导意义。

1 智能电能表自动化检定系统的检定数据

1.1 基于统计的数据特征提取

智能电能表自动化检定系统检定工作主要是由一套电气回路的60个检定表位形成一个检定单元,通常一条检定流水线包含30个检定单元,在每一次的检定任务中,来自同一批次的智能电能表被随机分配到不同表位中,进行多项不同的误差实验,所得到的误差实验数据除了反映智能电能表本身的质量问题外,还可以间接反映检定装置本身的问题。

假定同一批次的智能电能表的计量性能具有相同的分布特征,在所有检定表位均处于正常状态且状态一致时,认为处在同一检定单元的60个检定表位所对应的误差实验数据也应该具有相同的分布特征,当某个检定表位出现例如锈蚀、变形等故障时,其分布特征将与其他表位不同,表现为“异常”数据点。为便于在海量的误差实验数据中提取数据分布特征值,对在同一检定表位产生的海量误差实验数据进行相关统计量的计算:基于同一检定表位产生的数据,分别统计每个实验项目数据中的最大值、最小值,计算其期望、方差、偏度和峰度,用于描述该检定表位的数据分布的平均水平、离散程度、不对称性和极端异常值占比,将表位异常状态转换为数据分布的异常。

1.2 基于PCA的数据降维

检定系统下一条流水线包含30个检定单元,每一个检定单元的试验数据集包含60个检定表

位样本,即 $\{X_1, X_2, \dots, X_{60}\}$,分别计算每个表位对应每一项误差实验数据的最值、期望、方差、偏度和峰度,构建每个表位样本的特征,以进行 m 项误差实验为例,则每个样本包含 $6m$ 个特征值,即 $6m$ 个维度。

为防止较大尺度的数据弱化其他特征数据的影响,致异常因子算法的预测性能降低,将样本的各个特征值缩放到相同的尺度下,采用标准化特征缩放处理数据,公式如下:

$$z = \frac{x - u}{s} \quad (1)$$

式中: x 为待处理特征值; u 为待处理特征数据集的期望; s 为待处理特征数据集的标准差; z 为经过标准化后的特征值。

标准化可以使样本的所有特征保持均值为0,方差为1。

国网上海市电力公司对智能电能表的检定过程进行了十项误差实验,则每个检定表位样本的数据维度高达60维度,由于一个鉴定单元最多可获得60个鉴定表位样本,在数据维度接近甚至超过样本数量的情况下,数据样本分布稀疏,对其进行概率密度函数设计会比较困难,设计分类器也很困难,无疑给异常检测增加了难度,所以对数据集进行降维处理是有必要的。主成分分析(principal component analysis, PCA)是最常用的一种降维方法,其算法如下所示:

输入:样本集 $D=\{X_1, X_2, \dots, X_{59}, X_{60}\}$;

过程:

1)对所有样本进行中心化:

$$X_i \leftarrow X_i - \frac{1}{60} \sum_{i=1}^{60} X_i;$$

2)计算样本的协方差矩阵 XX^T ;

3)对协方差矩阵 XX^T 做特征值分解;

4)取最大的 d' 个特征值所对应的特征向量 $W_1, W_2, \dots, W_{d'}$;

输出:投影矩阵 $W=(W_1, W_2, \dots, W_{d'})$ 。

降维后的维度 d' 由用户指定,不同维度下的数据特征信息占比不同,用户可通过设定想要保留的特征信息占比来确定 d' 的取值。智能电能表自动化检定系统的数据样本在不同 d' 值时对应的特征保留信息占比如图1所示。

标准化后的样本数据,若要保留接近99.9%的特征信息,需要数据维度在40维以上,即用于异常检测算法分析的有效数据维数为40维度。

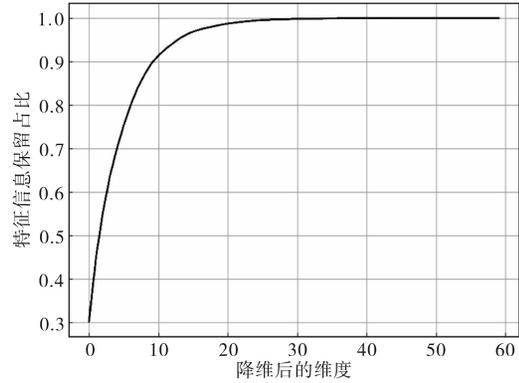


图1 不同维度下的样本特征信息保留占比

Fig.1 Proportion of sample characteristic information retention under different dimensions

2 异常检测模型的构建流程与算法原理

2.1 TSVM 模型构建流程

TSVM模型构建方法如下:

步骤一:对包含少量异常数据的待测检定表位数据进行特征提取、构建特征向量,并进行PCA降维处理;

步骤二:选择准确率较高的无监督异常检测算法筛选出“异常表位”,交由人工进行检查,在排除故障的同时获得标记样本;

步骤三:利用标记样本与未标记样本以半监督方式获得基于TSVM的异常检测模型。

另外,为了提升TSVM模型性能,可多次利用新的标记样本按照半监督方式对模型进行优化,优化模型性能的方法为:先利用TSVM模型预测出待检测样本中的异常数据,交由人工进行检查,然后用所有获得人工标记的样本构建标记样本库,从中选取距离分类边界较近的数据点构成新的标记样本,与未标记样本按照半监督方式优化TSVM模型;用优化后的TSVM模型对标记样本库中的数据点进行预测,计算标记样本的预测状态与真实状态之间差异的比率,其值小于人为设定的阈值时,判定该模型性能满足预测准确度条件。经过优化后的TSVM模型可直接对待检测数据集进行预测。

2.2 标记样本的选取办法

所构建的模型只需要小部分的标记样本,通过采用无监督异常检测算法,在原始不纯净的无标签样本中筛选出异常表位样本,再交给人工对这些表位进行标记。孤立森林(isolation forest, IForest), 局部异常因子(local outlier factor, LOF),

一类支持向量机(one-class support vector machine, OCSVM)是目前流行且效果较好的三种无监督异常检测算法:

1)孤立森林(Iforest):Iforest算法对全局异常检测的效果较好,适合对连续型、较高维度的数据进行异常检测。Iforest算法是多次二叉树式的划分过程,每次随机抽取数据集的特征,随机取值作为划分依据对数据集进行划分,经过多次迭代,直到在森林中形成一棵孤立的树^[13]。样本数据点在树中所处的位置越低,被判为异常数据点的可能性越大。

2)局部异常检测(LOF):LOF算法对全局异常点的检测效果不如Iforest,但对数据分布比较集中、异常比重较小的数据集的局部异常检测效果较好。LOF算法是基于密度的离群点检测方法,通过计算样本点的第K邻域(非全局)来确定局部可达密度,通过比较样本点与其邻域点的局部可达密度来判断样本是否为异常点,样本点的密度越低,越可能是异常点。

3)一类支持向量机(OCSVM):OCSVM是一种经过修改的支持向量机类型,适合奇异值检测以及样本不平衡场景,对高维度、大样本数据的异常检测效果好。OCSVM模型的训练样本仅为一类数据,通过建立出可代表该类数据的模型,获取数据集的分布形状,从而在检测过程中,判断待预测的数据样本是否与训练样本同属于一类数据。

标记样本的选取原则是尽量减少标记代价,选择最可能是异常数据点的样本进行标注,在排除表位故障的同时,还有助于较快发现新的异常类型。为了选出适用于智能电能表自动化检定系统数据的无监督异常检测算法,选择机器学习库中的Letter高维异常数据集来检测三种无监督异常检测算法的准确率,其数据维度以及异常程度与经过PCA降维处理的智能电能表自动化检定系统数据相似,Letter数据集的维度为32,样本量为1600,其中异常样本数为100,采用交叉验证法优化模型算法的参数,实验结果如表1所示。

表1 无监督异常检测的平均准确率

Tab.1 Average accuracy of unsupervised anomaly detection			
异常检测算法	Iforest	LOF	OCSVM
平均准确率	89%	91%	67%

选取具有较高准确率的LOF算法,通过无监督方式在原始数据集中筛选出“异常数据点”,再交给人工进行核查。

2.3 半监督支持向量机原理

TSVM作为半监督支持向量机模型的代表,与支持向量机(support vector machine, SVM)一样,是解决二分类问题的算法,可用在半监督式异常检测场景中,并且适合标记样本数量较少的情况。

标记样本 $D_l = \{(x_1, y_1), (x_2, y_2), \dots, (x_L, y_L)\}$, 其中 $y_i \in \{-1, +1\}$, -1表示异常, +1表示正常,未标记样本 $D_u = \{x_{L+1}, x_{L+2}, \dots, x_m\}$, TSVM算法通过尝试未标记样本的所有标记组合,找到一个能让所有样本之间的间隔最大化的超平面^[14],该算法最终给出的未标记样本的标记应该满足下式:

$$\begin{cases} \min \frac{1}{2} \|\mathbf{w}\|_2^2 + C_l \sum_{i=1}^L \varepsilon_i + C_u \sum_{i=L+1}^m \varepsilon_i \\ \text{s.t. } y_i(\mathbf{w}^T x_i + b) \geq 1 - \varepsilon_i \quad i = 1, 2, \dots, L \\ \widehat{y}_i(\mathbf{w}^T x_i + b) \geq 1 - \varepsilon_i \quad i = L + 1, L + 2, \dots, m \end{cases} \quad (2)$$

其中 $\varepsilon_i \geq 0 \quad i = 1, 2, \dots, m$

式中: (\mathbf{w}, b) 为一个超平面; ε_i 为与所有样本一一对应的松弛向量; C_l 与 C_u 分别为代表标记样本与未标记样本权重的折中参数。

具体算法流程如下所示:

输入: D_l, D_u, C_l, C_u ;

过程:

1)用 D_l 训练一个 SVM_l;

2)用 SVM_l 对 D_u 中的样本进行预测,得到 $\mathbf{y} = (y_{L+1}, y_{L+2}, \dots, y_m)$;

3)初始化 $C_u \ll C_l$;

4)while $C_u < C_l$ do

基于 $D_l, D_u, \mathbf{y}, C_l, C_u$, 求解式(2)得到 $(\mathbf{w}, b), \varepsilon$

while $\exists \{i, j | (y_i y_j < 0) \wedge (\varepsilon_i > 0) \wedge (\varepsilon_j > 0) \wedge (\varepsilon_i + \varepsilon_j > 2)\}$ do

$y_i = -y_i$;

$y_j = -y_j$;

基于 $D_l, D_u, \mathbf{y}, C_l, C_u$, 重新求解式(2)得到 $(\mathbf{w}, b), \varepsilon$

end while

$C_u = \min\{2 C_u, C_l\}$

end while;

输出: D_u 的预测结果: $\mathbf{y} = (y_{L+1}, y_{L+2}, \dots, y_m)$ 。

3 实例分析

文中数据来自国网上海市电力公司智能电能表自动化检定系统,该系统的被检设备类型为三相智能电能表,选取数据为2020年11月10日到2020年11月13日,批次号为JYL20002的检定数据;该系统对每个智能电能表进行10项误差实验,在自动化检定系统中共产生了196 790条误差实验数据。

3.1 数据特征

该条检定系统下流水线共有30个检定单元,每个检定单元的数据集包含60个检定表位样本,基于每个检定表位产生的10项误差实验数据,构建其特征向量,每个样本的特征向量包含60个特征值,以1号检定单元的1号检定表位为例,其各项特征值如表2所示。对1号检定单元的60个样本的特征向量进行标准化处理和降维,由原先的60维度降至40维度,降维后的数据特征如表3所示。

表2 表位样本的特征值(1号样本为例)

Tab.2 Eigenvalues of epitope samples (sample 1 as an example)

实验项目	特征					
	Max(X)	Min(X)	E(X)	D(X)	Skew(X)	Kurt(X)
项目1	0.007 0	-0.050 9	-0.023 917	0.000 406	0.106 826	-1.541 011
项目2	-0.013 5	-0.074 0	-0.048 492	0.000 418	0.457 221	-0.870 495
项目3	0.002 2	-0.111 7	-0.032 800	0.000 985	-1.535 648	2.775 146
项目4	0.043 3	-0.085 1	-0.001 425	0.001 208	-1.134 629	2.165 499
项目5	0.067 6	-0.160 5	-0.004 658	0.003 671	-1.547 250	3.437 145
项目6	0.109 3	-0.121 6	0.026 133	0.003 655	-1.176 047	2.458 465
项目7	0.011 7	-0.050 0	-0.020 842	0.000 300	0.221 488	-0.173 168
项目8	-0.022 7	-0.085 2	-0.058 567	0.000 412	0.554 031	-0.820 532
项目9	0.010 2	-0.053 5	-0.021 258	0.000 407	-0.017 970	-1.203 731
项目10	-0.023 8	-0.087 6	-0.062 267	0.000 447	0.601 206	-0.686 866

表3 经过PCA降维后的特征数据

Tab.3 Feature data after PCA dimensionality

表位号	维度						
	1	2	3	38	39	40
1	-2.234 622	1.585 350	2.526 461	-0.001 673	0.035 707	-0.030 962
2	-1.229 589	2.076 074	-2.800 221	-0.046 646	-0.046 169	0.070 169
3	-1.296 936	-0.182 465	1.629 265	0.099 782	-0.086 831	0.027 047
						
58	-3.462 262	-0.090 737	1.551 019	0.139 304	-0.034 429	-0.087 262
59	-1.508 056	-1.500 644	-0.810 303	0.055 930	0.147 360	-0.142 620
60	-1.336 344	3.994 048	-0.853 882	0.040 263	-0.094 883	0.169 225

3.2 无监督异常检测结果

考虑到检定单元之间还可能存在着标准表误差不同以及电气回路存在故障等问题,在获取标记样本时,以同一检定单元的表位样本作为待测数据集,采用LOF异常检测算法,通过表位的特征数据计算该检定单元中每个表位的异常因子数值(表征每个样本的异常程度),然后采用箱型

图法对同一检定单元的60个表位样本的异常因子数值进行异常筛选,筛选出最可能是异常数据点的表位样本,交由人工对“异常表位”进行检查。将无监督式异常检测算法应用于该批次(JYL20002)的30个检定单元,可以得到1 800个检定表位的异常因子数值,其中1号检定单元的60个检定表位的异常因子数值如表4所示。

表4 无监督异常算法结果

Tab.4 Results of unsupervised anomaly algorithm

表位号	异常因子数值	表位号	异常因子数值	表位号	异常因子数值	表位号	异常因子数值
1	1.130 353	16	1.031 647	31	1.058 620	46	1.046 426
2	1.014 464	17	1.010 069	32	2.000 560	47	1.320 810
3	1.004 347	18	0.998 419	33	1.197 083	48	1.098 991
4	1.054 612	19	1.044 121	34	2.334 983	49	1.207 244
5	1.000 622	20	1.015 149	35	1.857 913	50	1.167 582
6	0.995 484	21	1.000 194	36	1.007 053	51	2.695 171
7	1.023 143	22	1.140 063	37	1.077 457	52	3.494 880
8	1.012 834	23	1.268 981	38	1.010 256	53	2.956 908
9	1.008 601	24	1.022 946	39	1.033 592	54	1.007 359
10	1.026 758	25	1.106 047	40	1.008 499	55	1.027 882
11	1.883 877	26	1.065 297	41	1.010 359	56	1.188 867
12	1.054 852	27	1.217 648	42	0.996 309	57	1.050 760
13	1.121 655	28	1.267 209	43	1.160 934	58	0.998 736
14	1.010 204	29	1.003 913	44	1.026 550	59	1.015 013
15	0.997 774	30	1.097 910	45	0.996 525	60	0.999 981

应用箱型图方法对上述异常因子数值进行异常检测:根据人工检查经验得到鉴定单元中故障表位的占比,以此来调整箱型图的上限阈值,将该阈值作为无监督算法中正常与异常的分类边界,将超过该阈值距离的样本判定为异常样本,此鉴定单元取 1.397 58 作为判定值,1号检定单元中被判定为异常的表位为:11,32,34,35,51,52和53号,经过人工检查发现,11,51,53故障,而32,34,35,52无故障,同样的无监督异常检测算法应用于整条流水线数据,判定为异常的表位有322个,经过人工核查,其中无故障的表位有230个,显而易见,无监督异常检测在智能电能表异常检测方面的应用存在误判率较高的问题。

3.3 TSVM模型预测结果

TSVM利用无监督异常筛选与人工检查获取到的小标记表位样本集训练出一个初始SVM,接着使用该学习器对未标记表位样本进行打标,这样所有样本都有了标记,基于这些有标记的样本重新训练SVM,之后再寻找易出错样本不断调整。

为了检测模型性能,采用了机器学习中将样本随机划分为训练集和测试集的方法,但与直接将样本进行随机划分的应用不同,基于同一鉴定表位在同一误差实验项目中会生成数百条实验数据,所以将该方法应用到相同表位的同一误差实验项目的数据集,将其随机划分为“训练集”和“测试集”,用于模拟流水线在两次不同工作过程中得到的检定数据集,再经过特征提取、标准化

和降维处理得到训练样本与测试样本。

训练样本中包括标记样本和未标记样本,以1号单元为例,其中经过人工检测的11,32,34,35,51,52和53号表位样本数据可作为有标记样本 X_i ,用-1和+1表示检定表位的故障和正常状态:

$$D_1 = \{(X_{11}, -1), (X_{32}, +1), (X_{34}, +1), (X_{35}, +1), (X_{51}, -1), (X_{52}, +1), (X_{53}, -1)\}$$

而未经过人工核查的其他表位可作为未标记样本集:

$$D_u = \{X_1, X_2, \dots, X_{10}, X_{12}, \dots, X_{31}, X_{33}, X_{36}, \dots, X_{50}, X_{54}, \dots, X_{60}\}$$

利用标记样本与未标记样本按照半监督方式训练得到TSVM模型,通过网格寻优方法调整参数 C_1, C_u ,以提高模型准确性,应用该模型对“测试集”进行预测,其预测结果与无监督异常检测算法结果对比如表5所示。

表5 TSVM与LOF异常检测结果对比

Tab.5 Comparison of anomaly detection results of TSVM and LOF

	LOF检测	人工检测	TSVM检测
11号表位	-1	-1	-1
32号表位	-1	+1	+1
34号表位	-1	+1	+1
35号表位	-1	+1	+1
51号表位	-1	-1	+1
52号表位	-1	+1	+1
53号表位	-1	-1	-1

通过模型预测结果可以看出,相比无监督异常检测模型而言,所构建的TSVM模型具有更高准确率。

4 结论

针对智能电能表自动化检定系统实现检定表位的在线异常检测的难题,提出了构建基于TSVM模型的异常检测模型的方法:面对不纯净的检定表位样本,首先以无监督方式筛选出最可疑的表位样本,交由人工进行标记,在排除表位故障的同时,获得部分标记样本数据,然后利用标记样本与未标记本来构建TSVM模型。实验结果表明,所构建的异常检测模型可以实现流水线表位异常的在线检测,减少由于停运检修带来的工作量,能提高流水线的工作效率;算法模型与无监督异常检测方法对比,基于半监督学习方式的TSVM模型具有更高的精准度,并且该模型能够通过主动学习方式,选取有利的标记样本训练模型:从标记样本库中选择更多邻近分类边界的样本作为标记样本,提供给TSVM模型进行学习,达到提升模型性能的目的,主动学习的方法为智能电能表自动化检定系统在今后的工作过程不断优化和改进TSVM模型性能提供了思路。

参考文献

- [1] Ferrigno L, Paciello V, Pietrosanto A. Visual sensors for remote metering in public networks[C]//Instrumentation and Measurement Technology Conference, Binjiang: IEEE, 2011:1-6.
- [2] Wang Rui, Yu Hai-bo. Failure risk assessment method of electric energy meter based on state evaluation[C]//China International Conference on Electricity Distribution, Xi'an: IEEE, 2016: 1-5.
- [3] 吴海波. 智能电表在智能电网中的作用及应用前景[J]. 技术与市场, 2016, 23(6): 288-290.
Wu Hai-bo. Function and application prospect of smart meter in smart grid[J]. Technology and Market, 2016, 23(6): 288-290.
- [4] Sun Qie, Li Hailong, Ma Zhanyu, et al. A comprehensive review of smart energy meters in intelligent energy networks[J]. IEEE Internet of Things Journal, 2016, 3(4): 464-479.
- [5] 黄文江, 史焕弘, 吴思远. 智能电表自动化检定系统应用分析[J]. 计算机产品与流通, 2019(4): 131.
Huang Wenjiang, Shi Huanhong, Wu Siyuan. Application analysis of smart meter automatic verification system[J]. Computer Products and Circulation, 2019(4): 131.
- [6] 杨东升, 鲁观娜, 丁恒春, 等. 电能表自动检定流水线模糊故障诊断专家系统[J]. 电测与仪表, 2017, 54(7): 94-96, 102.
- [7] 杨海, 戴太文, 卢树峰, 等. 基于数据挖掘的计量装置在线监测与故障诊断系统设计[J]. 电子设计工程, 2016, 24(23): 108-111.
Yang Hai, Dai Taiwen, Lu Shufeng, et al. Design of online monitoring and fault diagnosis system for metering device based on data mining[J]. Electronic Design Engineering, 2016, 24(23): 108-111.
- [8] 王立斌, 王洪莹, 张超. 电能表自动化检定流水线设备最佳检修频率的研究[J]. 电测与仪表, 2017, 54(8): 89-92.
Wang Libin, Wang Hongying, Zhang Chao. Research on optimal maintenance frequency of automatic verification assembly line equipment for electric energy meter [J]. Electrical Measurement and Instrument, 2017, 54(8): 89-92.
- [9] 王立斌, 高波, 赵佩, 等. 电能表自动化检定流水线表位故障定位及报警系统设计[J]. 河北电力技术, 2018, 37(1): 33-34, 48.
Wang Libin, Gao Bo, Zhao Pei, et al. Design of fault location and alarm system for watt hour meter automatic verification assembly line [J]. Hebei Electric Power, 2018, 37(1): 33-34, 48.
- [10] 邵淮岭. 一种自动化检定流水线的风险预警和评估方法研究[J]. 电力与能源, 2016, 37(5): 561-563.
Shao Huailing. Research on risk warning and evaluation method of automatic verification line[J]. Electricity and Energy, 2016, 37(5): 561-563.
- [11] Campos G O, Zimek A, Meira W. An unsupervised boosting strategy for outlier detection ensembles[C]//Proc of Pacific-Asia Conference on Knowledge Discovery & Data Mining, 2018: 564-576.
- [12] 夏火松, 孙泽林. 基于自编码器和集成学习的半监督异常检测算法[J]. 计算机工程与科学, 2020, 42(8): 1440-1447.
Xia Huosong, Sun Zelin. Semi-supervised anomaly detection algorithm based on self-encoder and ensemble learning[J]. Computer Engineering and Science, 2020, 42(8): 1440-1447.
- [13] Sridhar Alla, Suman Kalyan Adari. Python深度学习异常检测[M]. 北京:清华大学出版社, 2020: 24.
Sridhar Alla, Suman Kalyan Adari. Using Python programming and deep learning algorithm for anomaly detection [M]. Beijing: Tsinghua University Press, 2020: 24.
- [14] 周志华. 机器学习[M]. 北京:清华大学出版社, 2016: 298-300.
Zhou Zhihua. Machine learning[M]. Beijing: Tsinghua University Press, 2016: 298-300.

收稿日期:2021-03-09
修改稿日期:2021-04-26