

4-10-2023

Load type identification method of 10 kV transmission line clock-inaccuracy metering point based on bayesian network

Yifan QING

College of Electrical Engineering, Sichuan University, Chengdu 610065 , China

Qun ZHOU

College of Electrical Engineering, Sichuan University, Chengdu 610065 , China

Renjian ZHANG

Nanchong Power Supply Bureau of Sichuan Power Grid, Nanchong 637001 , China

Follow this and additional works at: <https://jepst.researchcommons.org/journal>

Recommended Citation

QING, Yifan; ZHOU, Qun; and ZHANG, Renjian (2023) "Load type identification method of 10 kV transmission line clock-inaccuracy metering point based on bayesian network," *Journal of Electric Power Science and Technology*. Vol. 38: Iss. 1, Article 14.

DOI: 10.19781/j.issn.1673-9140.2023.01.014

Available at: <https://jepst.researchcommons.org/journal/vol38/iss1/14>

This Article is brought to you for free and open access by Journal of Electric Power Science and Technology. It has been accepted for inclusion in Journal of Electric Power Science and Technology by an authorized editor of Journal of Electric Power Science and Technology.

基于贝叶斯网络的 10 kV 线路时钟超差 计量点负荷类型识别方法

青倚帆¹, 周 群¹, 张仁建²

(1. 四川大学电气工程学院, 四川 成都 610065; 2. 四川国网南充供电局, 四川 南充 637001)

摘 要: 10 kV 线路上负荷计量点处出现时钟超差将导致线损率异常, 而现有人工排查方法存在效率低、智能化程度不高的问题。为此, 提出一种基于线损率曲线波动特征识别时钟超差计量点负荷类型的新方法, 通过贝叶斯网络(BN)拟合负荷类型与时钟超差线损率的映射关系。为解决时钟超差样本缺乏的问题, 在基于线路实际运行数据的仿真模型中对负荷计量点分别设置计量时钟偏差模块, 生成时钟超差线损率样本集; 引入模糊 C 均值聚类, 根据负荷曲线形状相似度对负荷进行归类, 在负荷较多的场景中实现数据降维。依托于同期线损系统的研究数据, 算例分析验证了该方法的可行性和准确性, 说明其可实现时钟超差计量点负荷类型辨识, 为快速定位时钟超差异常电能表提供参考。

关 键 词: 时钟超差; 线损率; 模糊 C 均值聚类; 贝叶斯网络; 负荷类型识别

DOI: 10.19781/j.issn.1673-9140.2023.01.014 中图分类号: TM73 文章编号: 1673-9140(2023)01-0122-08

Load type identification method of 10 kV transmission line clock-inaccuracy metering point based on bayesian network

QING Yifan¹, ZHOU Qun¹, ZHANG Renjian²

(1. College of Electrical Engineering, Sichuan University, Chengdu 610065, China;

2. Nanchong Power Supply Bureau of Sichuan Power Grid, Nanchong 637001, China)

Abstract: The clock-inaccuracy at the load measuring point on the 10 kV line leads to an abnormal line loss rate, while the existing manual methods have the problems of low efficiency and low intelligence. Therefore, based on the fluctuation characteristics of line loss rate curve, a new method for identifying the load types of clock-inaccuracy metering points is proposed to fit the mapping relationship between load type and the clock-inaccuracy line loss rate by Bayesian network (BN). In order to solve the problem of lack of clock-inaccuracy samples, the metering clock deviation modules are respectively set for the load metering points to generate a sample set of clock-inaccuracy line loss rate in the simulation model based on the actual operation data of the line. The fuzzy C-means clustering is then introduced to classify the load according to the shape similarity of the load curve, and the data dimensionality reduction is realized in scenarios with heavy load. Relying on research data from the synchronous line loss management system, the calculation example verifies the feasibility and accuracy of the proposed method. It is shown that the method can realize load type identification of clock-inaccuracy, and provide a reference for quickly locating the abnormal energy meters.

Key words: clock-inaccuracy; line loss rate; fuzzy C-means clustering; Bayesian network; load type identification

收稿日期: 2022-01-12; 修回日期: 2022-04-13

基金项目: 国家自然科学基金(51977134)

通信作者: 周 群(1966—), 女, 博士, 教授, 主要从事电工理论与新技术、新能源与电力电子研究; E-mail: zhouqunsc@163.com

线损率是评价电网企业经营管理水平的综合经济技术指标^[1],各电网公司已投运了同期线损管理系统,通过统计线损率指标考核线损管理水平^[2-3]。同期线损管理系统集多源系统,数据规模巨大,增长快速,具有大数据特征^[4],但管理人员对异常线损数据的分析手段有限。因此亟待丰富针对异常线损率的诊断方法^[5]。目前,线损异常诊断的相关研究主要集中在窃电检测和异常判定上,如文献[6]采用线损率、电压和电流的波动量作为特征,通过BP神经网络提高窃电检测的准确性;文献[7]基于数据驱动的方式,提出了线损数据缺失填充方法和考虑窃电检测在内的线损异常分析流程;文献[8]根据统计线损异常波动的数据特点,提出基于半监督神经网络的异常线损判定方法。时钟超差作为引发异常线损的常见原因,在异常线损诊断的相关研究较少。与此同时,某市供电公司线损管理数据显示,装配电能表中约有3%出现时钟超差异常,引发装配线路统计线损率指标正、负波动。因此,时钟超差问题在线损异常诊断中不可忽视。

时钟超差常表现为正超、负超2种形式,即电能表冻结时间相对系统冻结时间提前、延迟。在实际生产过程中,常采用人工比对方法排查电能表时钟超差,但该方法存在2个问题:排查流程采用Pearson相关系数等指标^[9-10],逐一分析比对各电能表电量变化与线路线损率变化的相关性,该方式在计量点众多的线路上排查效率低;时钟超差问题,可借鉴案例较少,缺乏系统的案例研究。因此,基于现有线路数据,建立高效、准确的时钟超差计量点负荷排查方法具有重要意义。

贝叶斯网络^[11](Bayesian network, BN)结合了图论和统计学,能够清晰且直观地描述各事件(节点)之间的关系,融合主观经验和客观数据^[12],在训练样本较少或缺失的情况下,仍然能保证良好的推理效果。目前,已有不少学者将BN应用于电力领域,文献[13]将BN应用于配电网拓扑辨识,实验结果证明该方法在数据较少、数据缺失情况下表现出较强鲁棒性;文献[14]将BN应用于电能表故障类型预测,具有较高的识别准确率;文献[15]建立基于BN的电力营销决策分析系统,用以分析线损管

理薄弱环节并指导线损管理目标;文献[16]将BN应用于电网复杂故障识别,能够整合专家知识、实验数据以及设备历史信息,提高信息利用率。

鉴于BN应用在小样本场景、故障辨识和线损异常分析等领域的显著优势,本文采用BN拟合时钟超差计量点负荷类型与线路线损率波动之间的映射关系。此外,基于实际负荷数据搭建异常场景仿真模型,生成时钟超差样本,解决样本缺乏的问题;采用模糊C均值聚类方法^[17]对待测样本负荷功率曲线做聚类处理,实现了负荷数据的降维。仿真实验结果表明,本文所提方法不仅能锁定时钟超差计量点的负荷类型,还能识别时钟超差的方向,实现智能化排查。

1 时钟超差数据的生成与预处理

时钟超差是配电网线损率异常波动的常见原因之一,实际生产中出现的时钟超差样本无法囊括一条线路上可能发生的所有情况。为此,在依托线路实际运行数据的线路仿真模型中,对负荷计量点分别设置计量时钟偏差模块,生成时钟超差线损率数据;提取周期性时钟超差线损率数据特征,以特定形式表示,生成时钟超差样本集。此外,10 kV线路上挂接负荷数量较多,若考虑所有负荷出现时钟超差的情况,会导致冗余数据过多,极大地增加了后续BN训练的复杂度。因此,本文在时钟超差线损率数据生成之前,采用模糊C均值聚类方法,实现负荷数据降维。

1.1 时钟超差线损率数据生成

为提高待测样本与异常线损率样本的匹配精度,并解决样本数据缺乏的问题,本文根据线路实际结构数据和运行数据针对线路搭建异常情况仿真模型,生成各负荷在不同偏差时间下的异常线损率数据,具体步骤如下:

1) 根据线路拓扑和各负荷计量点功率数据搭建仿真模型;

2) 针对线路上 N 个负荷设置计量时钟偏差模块,偏差时间为 $\Delta t_n, n \in [1, T]$,即可生成 $N \times T$ 个负荷一时钟超差场景下的仿真模型;

3) 运行仿真模型,记录各计量点电量数据,计算得到 $N \times T$ 个日线损率数据。

1.2 线损率波动特征提取

一个周期内的日线损率用向量 $r[r_1, r_2, \dots, r_k]$ (k 为一个统计周期的天数) 表示,可以反映周期性负荷对时钟超差线损率的影响。令线路理论线损率为 r_0 ,将线损率向量 $r[r_1, r_2, \dots, r_k]$ 中每个元素减去理论线损率 r_0 ,转化为线损率围绕理论线损率的波动幅度,生成波动向量 $b[b_1, b_2, \dots, b_k]$ 。接着对其做归一化处理,生成波动幅值比向量 $\lambda[\lambda_1, \lambda_2, \dots, \lambda_k]$,计算公式为

$$\lambda_i = \frac{b_i - \min\{b_i\}}{\max\{b_i\} - \min\{b_i\}}, i \in [1, k] \quad (2)$$

由式(2)可知,波动幅值比 λ_i 为连续型变量。若直接采用波动幅值比 λ_i 作为样本的特征参数,会导致后续BN训练效率较低,同时还可能伴有BN的过拟合。因此,需要对 λ_i 进行离散化处理。本文采用等区间法实现离散化^[18]。

对于一些周期性明显的负荷来说,其正、负超线损率曲线的极值点往往具有不同的分布。因此,构造曲线极点信息向量 $p[p_1, p_2, \dots, p_k]$ 作为特征。当某日线损率同时大于/小于相邻日线损率时,则视该日线损率为极点并取值 $p=1$,否则取 $p=0$ 。具体取值方法为

$$p_j = \begin{cases} 1, & (r_j - r_{j-1}) \cdot (r_j - r_{j+1}) > 0 \\ 0, & (r_j - r_{j-1}) \cdot (r_j - r_{j+1}) < 0 \end{cases} \quad (3)$$

式中, r_{j-1}, r_j, r_{j+1} 为连续3天线损率,其中 $j \in [1, k]$ 。

综上所述,本文采用波动幅值比向量 $\lambda[\lambda_1, \lambda_2, \dots, \lambda_k]$ 和极点信息向量 $p[p_1, p_2, \dots, p_k]$ 作为时钟超差负荷类型识别和方向识别的特征,以二维向量 $[A, B]$ 作为样本的标签,其中 A, B 分别为时钟超差的负荷类型和方向,生成时钟超差线损率样本库。

1.3 线路负荷聚类

由于负荷曲线形状相同的负荷在发生时钟超差时,波动幅值比向量 $\lambda[\lambda_1, \lambda_2, \dots, \lambda_k]$ 相同,为降低后续BN训练的复杂度,本文将负荷数据按负荷曲线形状相似度进行归类划分^[19]。

本文采用文献[17]提出的模糊C均值算法实现负荷聚类:选取具有参考意义的典型代表日,并将线路上所有负荷的24点负荷有功功率作为特征向

量,进行标准化处理。将所有负荷的原始功率矩阵用作算法的输入数据,并参考同期系统中该条线路上所有负荷标注的用电类别统计结果,设置聚类个数 M ,经模糊C均值聚类后得到各分类包含的 n_l ($l \in [1, M]$) 个负荷样本。

大容量负荷出现时钟超差更易引发线损率异常,因此根据各负荷容量在其所属类别总容量中的占比,将 n_l 个负荷拟合成一条负荷曲线,即

$$f^l(t) = k_1 f_1(t) + k_2 f_2(t) + \dots + k_{n_l} f_{n_l}(t), l \in [1, m] \quad (4)$$

式中, k_q ($q \in [1, n_l]$) 为第 q 条负荷容量在其所属类负荷总容量的占比系数,体现了负荷容量权重的影响。

基于模拟负荷,在时钟超差线损率仿真数据生成步骤2)中,不再对线路上所有负荷设置计量时钟偏差模块,仅将各拟合负荷代替各类型中容量最大的负荷,并设置计量时钟偏差模块,即可生成 $M \times T$ 个负荷类型—时钟超差场景下的仿真模型。

时钟超差数据生成及处理的过程如图1所示。




图1 异常线损率数据离线生成步骤

Figure 1 Offline generation steps of abnormal line loss rate samples

2 基于BN的时钟超差负荷类型识别

10 kV线路上不同负荷发生时钟超差时,线路线损率曲线呈现不同的变化形式。针对周期负荷,用统计线损率波动特征 $\lambda[\lambda_1, \lambda_2, \dots, \lambda_k]$ 和 $p[p_1,$

$p_2, \dots, p_k]$ 表征时钟超差引起的线路线损率变化,并用BN网络拟合线损率变化特征与时钟超差负荷类型之间的关系,建立基于BN的时钟超差计量点负荷类型识别方法框架如图2所示。




图2 基于BN的时钟超差负荷类型识别框架

Figure 2 BN-based identification framework of clock-inaccuracy load types

本文提出的10 kV线路时钟超差负荷类型识别方法框架主要分为3个部分:基于BN的时钟超差计量点负荷类型推理模型(后文称为BN推理模型)的搭建、时钟超差计量点负荷类型的在线识别和推理模型参数更新。

2.1 BN推理模型的搭建

BN在结构上可由一个有向无环图 $G=(V,E)$ 来表示。 $V=\{v_i\}$ 表示 i 个节点的集合, E 表示有因果关系的2节点之间的有向线段集。在考虑条件独立性假设时, G 中任意节点的联合概率表达式为

$$P(v_1, v_2, \dots, v_k) = \prod_{i=1}^k P(v_i | \pi(v_i)) \quad (5)$$

式中, k 为BN节点数; $\pi(v_i)$ 为 v_i 的父节点集。在得知网络结构的情况下,由式(1)可确定BN各节点的关系。后续可通过输入已知信息,更新各节点的后验概率即可推得结果。

本文提出的推理模型基于BN,需要通过样本集数据学习网络的结构和参数。BN的学习主要包括结构学习和参数学习,其目的在于通过样本学习BN的结构和联合概率分布。本文选择K2算法^[20]进行结构学习,贝叶斯方法进行参数学习。

在本文中,将负荷类型、时钟超差方向作为根节点,并用 $2k$ 个特征节点来表示2组特征向量参

数。K2算法按特征节点的日期顺序遍历,分波动幅值比、极点信息2个层次进行学习^[21-22]。

2.2 时钟超差计量点负荷类型的在线识别

当需要在线判断当前线损率波动情况下的时钟超差计量点负荷类型及时钟超差方向时,首先通过同期线损管理系统获取并统计当前周期线损率曲线的波动幅值比特征向量 $\lambda[\lambda_1, \lambda_1, \dots, \lambda_k]$ 和极点特征向量 $p[p_1, p_2, \dots, p_k]$;其次,将上述特征向量中的元素作为BN $2k$ 个特征节点的输入信息,并将BN中的2个根节点(负荷类型节点、时钟超差方向节点)作为输出节点;最后得到各类负荷出现异常和对应方向的概率,并选取概率最高的荷类型和时钟超差方向作为输出识别结果,即

$$o = \arg \max \{P_o\}, o \in \{a, b\} \quad (6)$$

当 $o=a$ 时, P_a 为BN推理后第 i 种负荷出现时钟超差的可能性;当 $o=b$ 时, P_b 为BN推理后时钟超差异常对应第 b 种方向的可能性。

2.3 BN推理模型参数更新

经BN推理模型推理后,排查目标被锁定在某类负荷中。将该类负荷按容量从大到小排序后,现场依次排查具体负荷,经现场排查确认识别结果正确后,将该案例作为训练样本,加入到异常线损率样本库中。进一步,重新计算新样本情况下BN推理模型的联合概率分布,更新BN的参数,提高BN的泛化能力,实现BN“训练—推理—更新—训练”的闭环结构,逐步提高时钟超差计量点负荷类型识别的准确性。

3 仿真算例分析

3.1 10 kV线路网络结构

为验证本文所提方法在时钟超差负荷识别上的有效性,本文根据IEEE 33节点标准配电系统搭建一条10 kV配电线路作为研究对象,如图3所示。

图3中共有34个计量点。其中,0节点为线路电能总计量点,测量整条线路的用电量;1~33节点为负荷计量点,测量各负荷用电量。依托同期线损系统,分别为各节点设置负荷,并尽量保证线路负荷容量分布均衡。




图3 IEEE 33节点系统10 kV线路

Figure 3 10 kV circuit diagram of IEEE 33-node system

3.2 线路负荷聚类

对线路上所有节点负荷进行标准化处理,并按照同期系统统计的负荷类型(轻工业、市政居民、重工业)设置线路负荷类别数 $M=3$,采用模糊C均值聚类的方法,对所有节点在最大负荷日的负荷进行分类,划分为I、II、III类负荷,对应的负荷类型在图3中用3种标识标注。各负荷节点对应的负荷容量及数量如表1所示。根据式(4)将各类负荷分别拟合成一条典型负荷曲线,分析它们的典型峰谷特性如图4所示。

通过对图4对比可知,3类负荷具有对应的典型峰谷特性:I类负荷曲线为常见的“双峰型”^[23];II类负荷曲线具有单峰单谷^[24]的特点,在夜间有用电高峰;III类有功负荷相对稳定,负荷峰谷值差异不大。通过负荷聚类,将33个负荷拟合成3类,实现了对负荷数据的降维。分析典型负荷峰谷的周期特性如图5所示。

表1 3类负荷对应负荷容量及数量

Table 1 The corresponding load capacity and quantity of the three types of loads

负荷类型	容量/(kV·A)	数量/个
I	630	2
	500	2
	400	6
	315	3
II	630	1
	500	4
	400	4
	315	1
	250	1
	200	2
	100	1
III	63	1
	1 250	3
	1 000	1
	800	1




图4 3类负荷的日负荷曲线(24 h)对比

Figure 4 Daily load curves (24 h) comparison of three types of loads




图5 3类负荷的峰谷周期曲线

Figure 5 Peak-to-valley cycle curves of three types of loads

通过图5对比3类负荷2周内功率峰谷曲线可知,3类负荷在用电低谷期的功率波动不大。此外,I类负荷与II类负荷的高峰期负荷具有明显的工作日高、周末低周期性变化规律。

因此,根据负荷的周期性,取特征向量周期为1周,波动幅值比向量 $\lambda[\lambda_1, \lambda_2, \dots, \lambda_k]$ 和极点信息向量 $p[p_1, p_2, \dots, p_k]$ 中 $k=7$ 。

3.3 样本生成

结合3周负荷运行数据,按照图3搭建Simulink线路仿真模型,并在仿真模型中分别对3类负荷加入计量偏差模块,实现不同偏差时间设置,生成3组仿真模型。模块中的偏差时间设置为24个正超偏差时间和24个负超偏差时间,运行仿真模型,得到432条1周时钟超差异常线损率曲线。对特征和标签进行统计并标注,形成以向量形式表示的样本集。最后按照留出法,以8:2的比例将总样本划分为345个训练样本和87个测试样本。

3.4 验证分析

3.4.1 BN推理模型搭建及测试结果

设置BN共16个节点,节点1为负荷类型节点,

节点2为时钟超差方向节点,节点3~9为线损率波动幅值比节点,节点10~16为极点节点,各节点信息如表2所示。

表2 BN节点信息

Table 2 Information of BN nodes

节点	类型	类别数
1	负荷类型	3
2	时钟超差方向	2
3~9	波动幅值比	10
10~16	极点情况	2

输入得到的345个训练样本,采用K2算法进行BN结构学习,获得BN推理网络结构拓扑如图6所示,并通过贝叶斯方法学习网络参数。至此,完成了文2.1提出的BN推理模型的构建。接下来,参照文2.2提出的步骤,用87个样本对其进行测试。进一步,将推理结果正确的样本作为新训练样本加入至训练样本库,实现文2.3中BN推理模型的更新。BN推理模型输出为测试样本时钟超差计量点负荷的所属类型,因此采用混淆矩阵评估模型推理结果如图7所示。

图7中,横、纵坐标分别表示时钟超差计量点负荷的预测、真实类型。通过混淆矩阵可以看出推理错误主要发生在I、II类负荷之间。




图6 时钟超差负荷类型BN推理网络模型

Figure 6 BN inference network model for clock-inaccuracy load type




图7 时钟超差计量点负荷类型推理结果混淆矩阵热力

Figure 7 Confusion matrix thermal diagram of abnormal load type reasoning results

3.4.2 对比分析

BN推理网络能够识别时钟超差计量点负荷类型和时钟超差方向,为分析BN推理网络的推理准确率,将测试样本结果分为4类,样本类型、占比如图8所示,样本数量如表3所示。




图8 BN模时钟超差负荷推理结果

Figure 8 BN inference result of abnormal load

表3 BN模型样本识别结果

Table 3 BN model sample identification results

编号	样本类型	数量/个
1	完全正确	70
2	仅负荷类型正确	5
3	仅时钟超差方向正确	5
4	完全错误	7

图8、表3中,时钟超差计量点负荷类型和时钟超差方向识别均正确/错误的样本称为完全正确/完全错误样本。在仅考虑负荷类型识别结果时,正确样本包括表3中编号为1、2的样本,共计86.2%的样本负荷类型识别正确。

同时,采用人工比对Pearson相关系数法^[7]对相同的87个测试样本进行测试,负荷类型识别准确率如图9、表4所示。




图9 Pearson分析法测试结果

Figure 9 Test results of the Pearson analysis

表4 Pearson样本识别结果

Table 4 Pearson sample identification results

编号	样本类型	数量/个
1	负荷类型识别正确	45
2	负荷类型识别错误	42

由图9、表4的测试结果可知,Pearson相关性分析法只能识别发生时钟超差的负荷,并且识别准确率相对较低。

对比本文所提方法与Pearson相关性分析方法,在3类负荷发生时钟超差时的识别准确度,结果如图10所示。




图10 BN网络与Pearson分析法识别正确率对比

Figure 10 Comparison of recognition accuracy between BN network and Pearson analysis method

由图10可知,本文所提方法在3类负荷的识别准确率上均优于Pearson相关性分析方法。此外,在平均容量较小的I、II类负荷出现时钟超差时,本文所提方法分别提升了28.5%、45.2%的识别准确率。以上测试结果表明:

1) 相较于人工统计Pearson方法,本文所提方法不仅能识别时钟超差计量点的负荷类型,还能识别时钟超差异常的方向;

2) 在训练样本数量有限的情况下,本文所提方法大幅提升了时钟超差计量点负荷类型的识别准确度。同时,相较于Pearson相关性分析方法,本文所提方法在数量较多、平均容量较小的I、II类负荷计量点出现时钟超差时,识别准确率提升更大。

4 结语

本文根据各类负荷在不同偏差时间的仿真模型获取时钟超差异常线损率数据,采用BN拟合各类负荷与时钟超差线损率的映射关系,实现时钟超差负荷类型识别。该方法在样本规模较小的情况下也能达到较高的识别准确率,将嫌疑负荷锁定在某一类型中。相较于传统人工比对方法,本文所提方法可以实现智能化排查,并识别时钟超差方向,在一定

程度上提高时钟超差计量点负荷排查的效率。本文的仿真实验结果表明:

1) 不同类型负荷计量点发生时钟超差的样本识别准确率有较大差别,负荷分类对BN推理模型准确性具有一定影响;

2) 在实际应用中,用于产生训练样本的某类负荷是由该类负荷中的多条负荷曲线拟合而来,与实际时钟超差负荷功率曲线形状不完全一致,存在无法避免的拟合误差。因此,后续将考虑通过优化连续变量离散化方法,求得更加精确的离散化区间,减少负荷拟合误差带来的线损率波动特征跨区间错误。

参考文献:

- [1] 王永明,陈宇星,殷自力,等.基于大数据分析的电力用户行为画像构建方法研究[J].高压电器,2022,58(10):173-179+187.
WANG Yongming, CHEN Yuxing, YIN Zili, et al. Research on construction method of power user behavior portrait based on big data analysis[J]. High Voltage Apparatus, 2022, 58(10): 173-179+187.
- [2] 段延宁.一体化电量与线损管理信息系统方案设计[D].保定:华北电力大学,2018.
DUAN Yanning. The integration of power and line loss management information system design[D]. Baoding: North China Electric Power University, 2018.
- [3] 唐登平,李俊,孟展,等.统计线损数据准确性研究[J].电力系统保护与控制,2018,46(24):33-39.
TANG Dengping, LI Jun, MENG Zhan, et al. Research on accuracy of statistical line losses[J]. Power System Protection and Control, 2018, 46(24): 33-39.
- [4] 王永平.台区线损管理与分析[M].北京:中国电力出版社,2020:9-19.
WANG Yongping. Line loss management and analysis in substation area[M]. Beijing: China Electric Power Press, 2020: 9-19.
- [5] 冯凯.同期线损管理系统应用指南[M].北京:中国电力出版社,2019:132-135.
FENG Kai. Synchronous line loss management system application guide[M]. Beijing: China Electric Power Press, 2019: 132-135.
- [6] 黄星知,杨奕纯,杨兰,等.基于BP神经网络的配电网窃电降线损研究[J].电力科学与技术学报,2019,34(4):143-147.
HUANG Xingzhi, YANG Yichun, YANG Lan, et al. Study of anti-power theft and line loss reduction for power

- distribution network based on BP neural network[J]. Journal of Electric Power Science and Technology, 2019, 34(4):143-147.
- [7] 蔡嘉辉. 基于数据驱动的线损异常智能分析方法研究及应用[D]. 无锡: 江南大学, 2021.
CAI Jiahui. Research and application of intelligent analysis method line loss anomaly based on data drive[D]. Wuxi: Jiangnan University, 2021.
- [8] 陈鑫鑫. 基于半监督径向基函数神经网络的统计线损异常诊断方法[D]. 北京: 华北电力大学, 2021.
CHEN Xinxin. Synchronous statistical line loss anomaly diagnosis method based on semi-supervised radial basis function neural network[D]. Beijing: North China Electric Power University, 2021.
- [9] 郑惠哲. 基于电能量数据管理的线损计算与异常分析[D]. 广州: 华南理工大学, 2018.
ZHENG Huizhe. Calculation and analysis of power loss based on electric energy data management[D]. Guangzhou: South China University of Technology, 2018.
- [10] 张斌, 李亚云, 李玉荣, 等. 计量自动化系统数据定位配电网线损异常方法[J]. 云南电力技术, 2017, 45(6):11-13.
ZHANG Bin, LI Yayun, LI Yurong, et al. A new method of abnormal line loss data location based on the data analysis of automated measurement system in distribution system[J]. Yunnan Electric Power, 2017, 45(6):11-13.
- [11] PEARL J. Fusion, Propagation, and structuring in belief networks[J]. Artificial Intelligence, 1986, 29(3):241-288.
- [12] 黄影平. 贝叶斯网络发展及其应用综述[J]. 北京理工大学学报, 2013, 33(12):1211-1219.
HUANG Yingping. Survey on Bayesian Network development and application[J]. Transactions of Beijing Institute of Technology, 2013, 33(12):1211-1219.
- [13] 任鹏哲, 刘友波, 刘挺坚, 等. 基于互信息贝叶斯网络的配电网拓扑鲁棒辨识算法[J]. 电力系统自动化, 2021, 45(9):55-62.
REN Pengzhe, LIU Youbo, LIU Tingjian, et al. Robust identification algorithm for distribution network topology based on mutual-information Bayesian network[J]. Automation of Electric Power Systems, 2021, 45(9):55-62.
- [14] 田英杰, 洪子靖, 周李. 基于函数型数据分析的工商业居民用户电力数据清洗算法[J]. 电测与仪表, 2021, 58(1):11-19.
TIAN Yingjie, HONG Zijiang, ZHOU Li. Data cleaning algorithm for industrial and commercial residential users based on functional data analysis[J]. Electrical Measurement & Instrumentation, 2021, 58(1):11-19.
- [15] 杨清银. 电力营销中贝叶斯网络决策分析系统应用研究[D]. 南京: 东南大学, 2019.
YANG Qingyin. Decision analysis of bayesian network in power marketing system application research[D]. Nanjing: Southeast University, 2019.
- [16] 朱保军, 咸日常, 范慧芳, 等. WRSR与改进朴素贝叶斯融合的变压器故障诊断技术研究[J]. 电力系统保护与控制, 2021, 49(20):120-128.
ZHU Baojun, XIAN Richang, FAN Huifang, et al. Transformer fault diagnosis technology based on the fusion of WRSR and improved naive Bayes[J]. Power System Protection and Control, 2021, 49(20):120-128.
- [17] 马宗彪, 许素安, 朱少斌, 等. 基于特征加权模糊聚类的电力负荷分类[J]. 中国电力, 2022, 55(6):25-32.
MA Zongbiao, XU Su'an, ZHU Shaobin, et al. Power load classification based on feature weighted fuzzy clustering[J]. Electric Power, 2022, 55(6):25-32.
- [18] 吴红, 王维平, 杨峰. 贝叶斯网络参数学习中的连续变量离散化方法[J]. 系统工程与电子技术, 2012, 34(10):2157-2162.
WU Hong, WANG Weiping, YANG Feng. Discretization method of continuous variables in Bayesian Network parameter learning[J]. Systems Engineering and Electronics, 2012, 34(10):2157-2162.
- [19] 陈芳, 张利, 韩学山, 等. 配电网线损概率评估及应用[J]. 电力系统保护与控制, 2014, 42(13):39-44.
CHEN Fang, ZHANG Li, HAN Xueshan, et al. Line loss evaluation and application in distribution network[J]. Power System Protection and Control, 2014, 42(13):39-44.
- [20] 张鸿勋. 基于K2评分的贝叶斯网结构学习算法的研究[D]. 北京: 北京工业大学, 2009.
ZHANG Hongxun. The research of bayesian network structure learning algorithm based on K2 score metric[D]. Beijing: Beijing University of Technology, 2009.
- [21] 方紫筠, 钱玉良. 含有用户自主选择行为分析的电价套餐设计策略[J]. 智慧电力, 2022, 50(5):94-99+105.
FANG Ziyun, QIAN Yuliang. Design strategy of electricity price package with analysis of user's independent choice behavior[J]. Smart Power, 2022, 50(5):94-99+105.
- [22] 查园园, 王亭岭, 上官伟. 基于贝叶斯网络的列控车载设备故障诊断[J]. 北京交通大学学报, 2021, 45(5):37-45.
ZHA Yuanyuan, WANG Tingling, SHANGGUAN Wei. Bayesian network-based fault diagnosis for on-board equipment of train control system[J]. Journal of Beijing Jiaotong University, 2021, 45(5):37-45.
- [23] 杨宏, 邓晨成, 邹芹, 等. 居民用电行为分析及潜力研究[J]. 电力大数据, 2020, 23(12):80-88.
YANG Hong, DENG Chencheng, ZOU Qin, et al. Analysis of residential electricity use behavior and potential research[J]. Power Systems and Big Data, 2020, 23(12):80-88.
- [24] 苏欣, 田浩, 秦昌龙, 等. 多变量数据聚类最优选择的用电关联分析算法[J]. 电网与清洁能源, 2022, 38(4):86-94+103.
SU Xin, TIAN Hao, QIN Changlong, et al. Electricity consumption association analysis algorithm for optimal selection of multivariate data clustering[J]. Power System and Clean Energy, 2022, 38(4):86-94+103.