

DOI: 10.19650/j.cnki.cjsi.J2514012

低压台区用户表前分支线漏电故障定位方法

陈 磊¹, 苏华锋², 苏 盛¹, 冯萧飞¹, 李 彬¹

(1. 长沙理工大学电气与信息工程学院 长沙 410014; 2. 广东电网有限责任公司东莞供电局 东莞 530221)

摘 要:针对低压台区表前漏电位置隐蔽性高,传统人工排查方式依赖于运维人员经验水平、间歇性漏电定位难度大等问题,提出了一种低压台区用户表前分支线漏电定位方法。首先基于电气先验知识,构建表前漏电物理模型分析漏电前后用户最短路径虚拟阻抗变化机理特征,建立台区用户多元线性回归方程求解用户时序虚拟阻抗矩阵,将其按列展平后作为后续模型输入。其次,建立邻近和全局关联对称相对熵模型,采用分段聚合改进模型计算输出形式,将表前漏电用户定位问题转化为时间序列异常检测问题。在传统重构损失函数中引入最小最大化对抗优化机制,提高模型对于单一关联特征的提取能力,进一步放大正常与表前漏电用户的特征差异。结合对称相对熵协同重构误差异常评分机制,将超出阈值分数的用户划归为异常用户。搭建 IEEE 欧洲低压馈线系统,仿真多种漏电场景获得充足训练样本后对模型进行最优调参和消融实验,结果表明所提模型检测性能较同类算法更优。最后,在考虑台区存在停电/空载用户特殊场景以及电表量测误差、电磁干扰等影响因素下,模型表现出较高的抗干扰性,并在真实台区测试中验证了所提模型的有效性和泛用性。

关键词: 低压台区;虚拟阻抗;邻近关联;全局关联;对称相对熵;表前漏电

中图分类号: TN912 TH89 **文献标识码:** A **国家标准学科分类代码:** 510.40

Leakage fault location method for branch lines before user meters in low voltage distribution system

Chen Lei¹, Su Huafeng², Su Sheng¹, Feng Xiaofei¹, Li Bin¹

(1. School of Electrical and Information Engineering, Changsha University of Science and Technology, Changsha 410014, China;

2. Dongguan Power Supply Bureau of Guangdong Power Grid Corporation, Dongguan 530221, China)

Abstract: To address the high concealment of pre-meter leakage locations in low-voltage distribution networks—as well as the limitations of traditional manual inspection methods that rely heavily on maintenance personnel experience and struggle with intermittent leakages—this paper proposes a branch-line leakage localization method targeting users on the customer side of the meter. First, leveraging electrical prior knowledge, a physical model of pre-meter leakage is established, and the underlying mechanism of changes in users' shortest-path virtual impedance before and after leakage is analyzed. Multivariate linear regression equations are then constructed for users in a distribution area to derive temporal virtual impedance matrices, which are flattened column-wise as model input. A symmetric relative entropy model is proposed to capture both local (adjacent) and global dependencies among users. Its output accuracy is enhanced through a segment aggregation strategy, effectively transforming the leakage localization problem into a time-series anomaly detection task. To improve the model's sensitivity to subtle feature deviations, a minimax adversarial optimization mechanism is introduced into the reconstruction loss function to amplify differences between normal and leaking users. This is further combined with a collaborative anomaly scoring method based on symmetric relative entropy, enabling robust identification of anomalous users exceeding a predefined threshold. Extensive simulations on the IEEE European low-voltage feeder system under various leakage scenarios are conducted to support hyperparameter tuning and ablation studies. Experimental results demonstrate that the proposed method outperforms existing algorithms in detection accuracy. Moreover, by addressing edge cases—such as outages, no-load users, measurement errors, and electromagnetic interference—the model exhibits strong anti-interference capability. Its effectiveness and generalization ability are further validated through deployment tests on real-world distribution networks.

Keywords: low voltage distribution networks; virtual impedance; adjacent dependency; global dependency; kullback-leibler; pre-meter leakage

0 引言

随着城市化进程的加快和电力需求的不断增长,低压配电网(lower voltage distribution system, LVDS)覆盖范围和用户数量显著增加,其供电线路走向及运行工况复杂多变,导致漏电故障频发,容易引发电气火灾、设备损坏和人员触电伤亡等问题^[1]。其中,因绝缘受潮或老化等因素影响,台区供电线路中架空线路或地下管线部分绝缘破损导致漏电,漏电位置隐蔽性较高^[2]。目前针对此问题主要依靠人工经验和传统仪器测量手段,在实时性、准确性和间歇性漏电检测定位能力方面存在局限性,亟需研究先进的表前漏电故障定位技术^[3]。

近年来,高速电力线通信(high speed power line communication, HPLC)智能电表在低压台区中广泛应用,不但能够实现瞬时电气量数据的高频采集报送,还具有时钟精准管理、相位拓扑识别、通信性能监测和网络优化等功能,有力支撑低压透明配电网建设,给低压配电网故障检测领域提供了良好的条件^[4]。研究人员基于台区计量时序数据利用机器学习等方法在相关领域应用效果显著^[5]。文献[6]基于运用 Apriori 算法挖掘台区剩余电流和故障用户负荷电流的强关联特性,采用自适应 Lasso 回归模型并结合回归系数快速识别表后户内漏电用户。文献[7]采用增强型超分辨率生成对抗网络模型对实现低分辨率数据的重构,显著提高低压台区接线错误漏电用户定位准确率。文献[8]基于台区剩余电流和用户负荷电流之间的关联关系,采用实数域多元回归识别异常用户。文献[9]在复数域内利用多元线性回归方法实现台区表后零线、地线错误漏电用户定位。文献[10]基于随机矩阵理论和边缘计算特征,提出一种数据驱动、边-云协同的低压配电网故障检测方法达到快速、准确定位配电网故障的目的。

当前国内外对于如何利用算法定位台区表前供电线路漏电缺乏必要的研究,尤其对于间歇性漏电,其随机性和不稳定性导致特征信号难以准确捕捉和识别,相比于持续性漏电定位难度更大。传统低压线路漏电故障定位研究大多为在低压线路两端安装剩余电流监测装置^[11],该方式仅适合在台区主干线上分段少量安装,若在台区边缘供带的大量用户分支线上应用存在设备成本高、运维复杂等实际问题。台区用户表前分支线因直接与用户相连接,若存在漏电故障,用户的触电风险更加显著。研究聚焦于表前分支线漏电故障问题,在不依赖台区相关拓扑参数信息条件下,基于现有的智能电表计量数据提

出数据驱动的台区用户表前分支线漏电故障定位方法。首先构建台区表前漏电物理模型,分析漏电故障前后用户最短路径虚拟虚拟阻抗变化机理,采用多元约束线性回归模型求解特征阻抗,建立对称相对熵模型量化正常和漏电台区的邻近与全局关联分布差异,采用分段聚合改进模型输出形式,将用户表前分支线漏电故障定位问题转化为时间序列异常检测问题;进一步在重构损失函数上引入对抗优化机制,提高模型对于漏电特征的检测能力,采用重构误差与对称相对熵协同打分机制,在模型消融实验、抗干扰实验和真实台区测试中验证了所提方法的有效性和泛用性。

1 台区表前漏电问题分析

1.1 表前漏电故障排查现状

如图1所示,低压台区用户表前漏电是指在低压配电网中,即用户电表之前(配电变压器到用户电表之间)由于树枝碰线、断线触地、生物触电或者线路绝缘破损等原因,导致电流通过接地或其他非正常导电路径流向地面的现象。特别是对于间歇性漏电故障,其表现为时断时续的剩余电流波动,常由临时性接触(如随风摆动的树枝碰线)或间歇性绝缘劣化引发,具有随机性强、隐蔽性高、故障持续时间短等特征,常规检测手段往往难以捕捉其瞬时特征。




图1 台区表前漏电场景示意图

Fig. 1 Diagram of pre-meter leakage in LVDS

长期以来,表前漏电故障排查方式基本靠人工经验,当剩余电流保护装置(residual current device, RCD)跳闸时,巡检人员根据 RCD 记录仪上剩余电流的大小初步判断故障原因后,再根据故障特征对低压线路进行巡检和故障排查^[12]。对于主干线或者分支线路绝缘损坏导致的漏电,巡检人员通常借助万用表、钳形电流表等工具从主干线中心点处登杆,通过逐段卡线测量剩余电流的方式缩小漏电故障排查范围。该方式存在人力成本高、效

率低下和安全风险高等缺点,不适应现代智能化需求,亟需采用更为先进的表前漏电故障定位技术来提升排查效率和准确度。

1.2 台区用户表前分支线漏电故障特征分析与计算

如图2所示,低压台区主要为辐射型网状结构,以单相电路为例定义用户的虚拟阻抗,即从变压器低压侧出口出发,连接用户和变压器的一条最小阻抗供电路径的等效阻抗。该阻抗与实际阻抗并不完全一致,因此定义为虚拟阻抗。考虑物理机理影响,进一步将用户的虚拟回路阻抗分成干线阻抗和支线阻抗。干线阻抗为供电回路中多个用户共用线路的等效阻抗;支线阻抗为供电回路中某用户独立线路的等效阻抗。




图2 台区C相用户2表前分支线漏电物理模型

Fig.2 Simplified physical model of pre-meter leakage on the C-phase branch line for a user in LVDS

以C相线路上的用户2为例,其最短供电路径虚拟阻抗如式(1)所示。

$$Z_{cir,c2} = Z_{cz,1} + Z_{cz,2} + Z_{cz,2} \quad (1)$$

式中: $Z_{cz,1}$ 、 $Z_{cz,2}$ 和 $Z_{cz,2}$ 分别为线路1、2 和用户2 的阻抗。具体而言, $Z_{cg,1}$ 与 $Z_{cg,2}$ 所在支路为共用线路, $Z_{cz,2}$ 所在支路为独自使用的支路。

定义用户2 的干线阻抗和支线阻抗如式(2)所示。

$$\begin{cases} Z_{gx,c2} = Z_{cz,1} + Z_{cz,2} \\ Z_{zx,c2} = Z_{cz,2} \end{cases} \quad (2)$$

式中: 干线阻抗 $Z_{gx,c2}$ 表示多用户共用供电线路的等效阻抗, 体现为从台变低压侧出口至用户分支点之间的线路电气特性; 支线阻抗 $Z_{zx,c2}$ 表示用户独立接入段的等效阻抗, 与用户自身电气特性直接相关。

联立式(1)、(2)可将用户2 虚拟阻抗公式改写如式(3)所示。

$$Z_{cir,c2} = Z_{gx,c2} + Z_{zx,c2} \quad (3)$$

基于上述根据用户干线、支线的定义, 对图2 中的用户2 列写最短供电路径基尔霍夫定律方程如式(4)所示。

$$U_C - U_{c2} = Z_{cz,1} I_{cg,1} + Z_{cz,2} I_{cg,2} + Z_{cz,2} I_{c2} = Z_{gx,c2} I_{gx,c2} + Z_{zx,c2} I_{c2} \quad (4)$$

式中: U_C 表示台区总表的C相电压; $I_{gx,c2}$ 表示用户2 的干线等效电流, U_{c2} 表示用户2 的电压; $I_{cg,1}$ 和 $I_{cg,2}$ 分别表示公共线路1段和2段的总电流; I_{c2} 表示用户2 的电流。

正常情况下, 用户2 的虚拟阻抗大小应保持相对稳定。若某时刻用户2 发生表前分支线漏电故障, 最小阻抗供电路径上将从漏电点引出一条新的漏电路径。从拓扑结构上来看, 等效于在用户2 最短供电路径上并联了一个接地阻抗 Z_G 和系统侧接地阻抗 Z_E , 此时故障状态下用户2 的虚拟阻抗 $Z'_{cir,c2}$ 将因为新增并联路径阻抗而减小, 相较于正常状态下的 $Z_{cir,c2}$, 该故障特征虚拟阻抗如式(5)所示。

$$Z'_{cir,c2} = Z_{cir,c2} \parallel (Z_G + Z_E) < Z_{cir,c2} \quad (5)$$

以每日96个点的多时段量测数据为数据源, 对用户2 建立回路方程时间序列如式(6)所示。

$$\begin{cases} U_C(t_1) - U_{c2}(t_1) = Z_{gx,c2} I_{gx,c2}(t_1) + Z_{zx,c2} I_{c2}(t_1) \\ U_C(t_2) - U_{c2}(t_2) = Z_{gx,c2} I_{gx,c2}(t_2) + Z_{zx,c2} I_{c2}(t_2) \\ \vdots \\ U_C(t_i) - U_{c2}(t_i) = Z_{gx,c2} I_{gx,c2}(t_i) + Z_{zx,c2} I_{c2}(t_i) \\ \vdots \\ U_C(t_k) - U_{c2}(t_k) = Z_{gx,c2} I_{gx,c2}(t_k) + Z_{zx,c2} I_{c2}(t_k) \end{cases} \quad (6)$$

式中: t_k 表示日测量周期内的任意采抄时刻, $t_k \in \{t_1, t_2, \dots, t_n\}$; U_C 和 U_{c2} 可分别从台区总表和用户电表采抄获取; I_{c2} 和 $I_{gx,c2}$ 可分别从用户电表采抄电流和通过基尔霍夫定律求取。

在台区供电系统运行中, 若存在停电/空载用户场景, 其负荷可能处于零状态, 即电表电流始终为0。此时式(4)构建的最短供电路径方程中, 由于该类用户分支线路的电流分量为0, 将导致分支线路压降计算结果为0, 进而忽略其阻抗的实际影响。考虑到分支线阻抗参数的缺失会直接影响台区用户虚拟阻抗的计算精度, 首先假设测量周期内台区所有用户均处于正常供电状态且台变与用户拓扑关系保持不变。即在仿真模拟时暂不考虑此类场景, 在4.3节中再进一步讨论该类场景对模型用户节点定位精度的影响。

需要强调的是, 当用户2 发生表前分支线漏电时, 新增对地漏电流 I_G 将参与式(4) 最短供电路径方程中用户2 的干线等效电流 $I_{gx,c2}$ 的合成, 干线与支线等效虚拟阻抗的计算也将受到不同程度的影响, 但仍会遵循式(4)的物理关系和式(5)的故障特征。基于上述分析,

以求取表前分支线漏电用户2虚拟阻抗为例目标进一步展开讨论。

对目标台区中每个用户列写式(6)时序方程,即构建以台区总表和用户电表电气参数为已知量,用户干线

$$\begin{bmatrix} Z_{cir,1}(t_1), & Z_{cir,2}(t_1), & \cdots, & Z_{cir,k}(t_1), & \cdots, & Z_{cir,n}(t_1) \\ Z_{cir,1}(t_2), & Z_{cir,2}(t_2), & \cdots, & Z_{cir,k}(t_2), & \cdots, & Z_{cir,n}(t_2) \\ \vdots & \vdots & & \vdots & & \vdots \\ Z_{cir,1}(t_k), & Z_{cir,2}(t_k), & \cdots, & Z_{cir,k}(t_k), & \cdots, & Z_{cir,n}(t_k) \\ \vdots & \vdots & & \vdots & & \vdots \\ Z_{cir,1}(t_n), & Z_{cir,2}(t_n), & \cdots, & Z_{cir,k}(t_n), & \cdots, & Z_{cir,n}(t_n) \end{bmatrix} \quad (7)$$

式中: $Z_{cir,k}(t_k)$ 表示任意用户 k 在测量周期内每日同一采样时刻 t_k 的虚拟阻抗计算值, $k \in \{1, 2, \dots, n\}$ 。

结合电气先验知识,正常状态下用户虚拟阻抗值应保持稳定,即台区正常用户间的时序虚拟阻抗相关性分布状态在时域上应保持稳定;当台区某用户表前分支线路发生漏电故障时,台区用户之间的时序相关性会有不同程度的削弱,该削弱程度受用户之间电气互联属性的约束,即对邻近用户的影响较小,而对电气距离较远的用户影响较大。综合上述理论依据,研究假设台区用户之间本身存在一种固有的电气互联物理属性,这种物理属性可近似由式(7)不同列(用户)之间的时序虚拟阻抗相关性来表征,其大小应与用户之间电气距离大小呈反比,且电气距离越近的用户强关联性特征越明显。

2 表前漏电用户定位模型建立

2.1 全局和邻近关联特征提取

为提取并量化正常与漏电用户之间这种时序相关性分布变化特征,选用神经网络模型来学习此特征。考虑到传统循环神经网络(recurrent neural network, RNN)在捕捉长短期依赖关系上的不足,而 Transformer 模型中的自注意力机制(self-attention)能捕捉时间序列中不同时间点之间的长期依赖关系和趋势,即能得到每个用户与其他各个用户的时序虚拟阻抗数据关联权重分布情况,定义这种整体的关联权重分布为全局关联(global dependency),用全局关联可量化用户之间固有的电气互联属性。

时间序列的连续性使得相邻时间点本身具备邻近集中(adjacent-concentration)的归纳偏好(inductive bias)属性^[13],异常点的稀疏性使其强关联性集中分布在相邻的时间点上,即表前间歇性漏电用户时序虚拟阻抗数据很难与所有用户时序数据建立强关联,定义这种时序分布特性为邻近关联(adjacent dependency)。高斯核函数(gaussian kernel)通过指数衰减的方式度量样本间的相似度,即具有随着输入数据点之间的距离的增加而迅速

和支线阻抗参数为未知量的时序方程,通过联立测量周期内每日同一时刻的最短路径方程并采用多元线性回归法求解获得台区用户的等效时序虚拟阻抗矩阵如式(7)所示。

衰减的局部特性^[14],对于具有检测随机波形性和阶跃性的间歇性漏电检测具有高度敏感性。选用高斯核来捕捉这种强关联性局部集中特性。

为了进一步证明正常与漏电用户时序虚拟阻抗具备1.2节假设两种关联的分布特性,以用户2表前分支线路发生漏电故障为例,选取经后续4.1节中仿真环境下计算得到的,按照用户与台变之间电气距离排序的一组表前分支线漏电台区用户时序虚拟阻抗两种关联量化数据,截取其正常和漏电时段台区用户时序虚拟阻抗数据绘制两种关联分布热力图如图3所示。




图3 台区正常和漏电时段台区用户关联性热力分布

Fig. 3 Correlation heat maps of user activity in the distribution area during normal and leakage periods

在图3中,正常和漏电时段台区用户时序虚拟阻抗的邻近关联分布非常相似,其强关联性皆集中于对角线上,即仅用户本身和邻近用户的数据点表现出强关联性,且随两用户之间电气距离增加,关联性大小呈现断崖式减小,这是由高斯核的局部特性所决定。对于

全局关联分布,正常和漏电时段台区用户时序虚拟阻抗的关联性大小随两用户之间电气距离增加而缓慢减小,这是由用户之间固有的电气互联属性所决定的。当用户2发生表前分支线漏电,台区用户时序虚拟阻抗全局关联分布发生变化,仅在漏电点邻近用户间的时序数据表现出强关联性,即局部表现出邻近关联分布相似的特性。

2.2 对称相对熵模型建立

由2.1节可知,全局关联特征是通过Transformer模型中的自注意力机制提取的台区用户之间虚拟阻抗时间

序列的跨用户依赖性关系,反映了用户间潜在电气耦合结构与拓扑属性。邻近关联特征则由高斯核函数计算,用以衡量单个用户在时间域上相邻采样点之间虚拟阻抗值的局部连续性和突变特性,具有良好的异常突变点检测能力,两种关联特征在正常与漏电台区表现出不同特征分布差异。为了量化这种差异特征,采用对称相对熵(kullback-leibler, KL)作为度量标准,对称相对熵可表示两个随机分布之间的相似度,相似度越高则代表两种关联的分布差异越小^[15]。基于上述原理来构建台区表前分支线漏电用户定位对称相对熵模型如图4所示。




图4 基于全局与邻近对称相对熵的台区表前漏电用户定位模型

Fig. 4 User localization model for pre-meter leakage in LVDS based on global and neighboring symmetric relative entropy

将1.2节中求解的式(7)台区用户时序虚拟阻抗矩阵数据按列展平后合并成一维矢量 $\hat{Z}$ 作为模型输入如式(8)所示。

$$\hat{Z} = \{Z_{cir,1}(t_1), \dots, Z_{cir,1}(t_n), Z_{cir,2}(t_1), \dots, Z_{cir,n}(t_n)\} \quad (8)$$

为了使模型能够有效地捕捉时间序列中的全局关联和邻近关联,首先需要对输入数据 $\hat{Z}$ 初始化处理,初始化公式如式(9)所示。

$$\begin{cases} Q = \hat{Z}^{l-1} W_l^Q \\ K = \hat{Z}^{l-1} W_l^K \\ V = \hat{Z}^{l-1} W_l^V \\ \sigma = \hat{Z}^{l-1} W_l^\sigma \end{cases} \quad (9)$$

式中: $Q, K, V \in \mathbb{R}^{N \times d}$ 分别表示查询(query)、键(key)和值(value),用于计算输入数据 $\hat{Z}$ 中各时间点的权值向量, $\sigma \in \mathbb{R}^{N \times 1}$ 表示一种自适应的尺度参数, $W_l^{Q,K,V,\sigma}$ 表示第 l 层对应的参数矩阵。

将每层初始化之后权值向量输入全局关联和邻近关联模型中。全局关联模型基于多头自注意机制挖掘出输入数据各时间点之间本质关系来计算关联权重;邻近关联模型基于 σ_i 和不同时间点 i 和 j 之间的距离采用自适应高斯核计算关联权重。这两种关联模型如式(10)和(11)所示。

$$G_l = \text{Softmax}(QK^T / \sqrt{d}) V \quad (10)$$

$$A_l = \text{Rescale}\left(\left[\frac{1}{\sqrt{2\pi}\sigma_i} e^{-\frac{|j-i|^2}{2\sigma_i^2}}\right]_{i,j \in \{1, \dots, N\}}\right) \quad (11)$$

式中: d 表示输入数据的特征维度; σ_i 表示时间点 i 对应的尺度参数; $|j-i|$ 表示时间点 i 和 j 之间的距离; $\text{Softmax}(\cdot)$ 表示归一化处理; $\text{Rescale}(\cdot)$ 表示标准化处理。

在获取 G_l 和 A_l 的权重分布后进一步采用对称相对熵(symmetric KL divergence)计算两种分布之间的信息增益^[16],以此来量化正常时序与异常时序之间的差异,具体如式(12)所示。

$$D(G, A) = \frac{1}{L} \sum_{l=1}^L (D(A_l \| G_l) + D(G_l \| A_l)) \quad (12)$$

式中: $D(G, A)$ 表示两个分布之间的对称相对熵; $D(\cdot \| \cdot)$ 表示两个分布之间的对称相对熵。式(12)表示将多层特征的全局和邻近关联的对称相对熵取平均,即通过量化得到一个可反应用户虚拟阻抗受漏电故障影响程度的度量值。

2.3 对抗优化策略

为进一步提高模型的特征学习能力,对于研究所提模型,采用以重构损失(reconstruction loss)最小为目标优化模型^[17],具体如式(13)所示。

$$\mathcal{L}(\dot{\mathbf{Z}}, \tilde{\mathbf{Z}}, \alpha, G, A) = \|\dot{\mathbf{Z}} - \tilde{\mathbf{Z}}\|_F^2 + \alpha \|D(G, A)\|_1 \quad (13)$$

式中: $\tilde{\mathbf{Z}}$ 表示时序数据 $\dot{\mathbf{Z}}$ 的重构值; α 表示损失系数 ($\alpha > 0$); $\|\cdot\|_F^2$ 表示重构约束部分; $\alpha \|\cdot\|_1$ 表示关联差异优化策略部分。

进一步引入关联差异对抗优化策略改进损失函数^[18], 即优化过程中分别将对称相对熵最小化和最大化, 而函数仍以重构损失最小为目标。为方便后续说明, 将两优化阶段分别命名为最小化阶段和最大化阶段。具体可将式(13)改写如式(14)所示。

$$\begin{cases} \mathcal{L}_{\min}(\dot{\mathbf{Z}}, \tilde{\mathbf{Z}}, \alpha, G, A) = \|\dot{\mathbf{Z}} - \tilde{\mathbf{Z}}\|_F^2 + \alpha \|D(G, A)\|_{1\min} \\ \mathcal{L}_{\max}(\dot{\mathbf{Z}}, \tilde{\mathbf{Z}}, \alpha, G, A) = \|\dot{\mathbf{Z}} - \tilde{\mathbf{Z}}\|_F^2 - \alpha \|D(G, A)\|_{1\max} \end{cases} \quad (14)$$

式中: G 和 A 表示在梯度计算中对特定关联进行梯度分离(detach), 即停止梯度反向传播, 确保函数在每个阶段仅针对特定关联进行优化^[19]。

在最小化阶段, 优化函数将迫使两个关联之间的差异最小化, 将全局关联从梯度计算中分离出来, 使得梯度计算只会影响邻近关联, 即调整邻近关联使其逐渐逼近全局关联从而更好的适应时序数据的各种时间模式; 反之, 在最大化阶段, 迫使两个关联之间的差异最大化, 将邻近关联逼近全局关联, 即更关注非邻近区域, 使异常点的重构变得更加困难, 从而提高模型的异常时间点的检测能力。

模型在对时序数据重构时, 对称相对熵和重构误差计算受制于重构质量的好坏, 为了避免单一指标在特殊情况下表现不佳影响模型评分效果, 设计对称相对熵与重构误差协同异常评分(anormal score, AS)机制^[20], 具体如式(15)所示。

$$AS(\dot{\mathbf{Z}}) = \text{Softmax}[-D(G, A)] \odot (\|\dot{\mathbf{Z}} - \tilde{\mathbf{Z}}\|_F^2) \quad (15)$$

式中: $AS(\dot{\mathbf{Z}}) \in \mathbb{R}^{N \times 1}$ 表示模型计算每个时间点的异常得分; $\text{Softmax}[-D(G, A)]$ 表示对称相对熵的负数归一化; $\odot$ 表示逐元素乘积(hadamard product)。

2.4 模型输出形式优化与阈值设定

模型计算每个时间点的异常得分后, 为使模型直观输出单个用户的异常分数, 采用文献[21]中时序分段聚合思想改进模型输出机制, 根据模型输入数据中单用户电表数据的采样间隔和测量周期设置分段大小, 使模型仅输出每个用户的异常分数, 减少模型检测时间。此外, 若该分段内任意一时间点的异常分数超出阈值 δ , 则将该分段内所有时间点标记为异常, 即该用户标记为异常,

该策略能有效提升模型检测间歇性漏电的能力。通过上述方式可将台区表前分支线漏电定位问题转化为时间序列异常检测问题。

模型阈值 δ 会根据预设值 r 自适应调整大小, r 表示输入数据中异常点期望比例, 该比例可根据技术人员实际需求变化进行调整, 较高的 r 值会使得模型输出更多的异常用户, 适用于漏电问题较多的台区, 但准确度可能会降低。具体来说, 对于任意一个用户数量为 n 的目标台区, 通常将 r 设置为 $1/n$, 异常分数阈值 δ 会自适应调整为只筛选异常分数最高的嫌疑用户, 即模型根据期望比例 r 确保只输出一个嫌疑用户, 以区分异常分数可能相近的用户。在稽查人员针对嫌疑用户表前分支线路故障消除之后, 可根据台区剩余电流大小来判断是否需要迭代模型, 直到台区剩余电流大小降至一级漏保跳闸阈值安全范围内(<300 mA)。

2.5 评价指标

异常检测通常采用混淆矩阵及其衍生指标来评价检测效果。为综合评价所提检测模型在不同场景下的性能, 选用了二分类方法中常用的评价指标: 准确率 δ_{ACC} 、召回率 δ_{TPR} 和 F1 分数 δ_{F1} ^[22]。具体计算公式如式(16)~(18)所示。

$$\delta_{ACC} = \frac{T_p + T_N}{T_p + F_N + F_p + T_N} \quad (16)$$

$$\delta_{TPR} = \frac{T_p}{T_p + F_N} \quad (17)$$

$$\delta_{F1} = \frac{2T_p}{2T_p + F_p + T_N} \quad (18)$$

式中: T_p 表示异常用户被检测为异常用户的用户数量; F_p 表示正常用户被检测为异常用户的用户数量; F_N 表示异常用户被检测为正常用户的用户数量; T_N 表示正常用户被检测为正常用户的用户数量。

3 台区表前分支线漏电用户定位流程

表前分支线漏电在低压台区中比较常见, 会使得漏电台区的用户最短路径时序虚拟阻抗关联分布较正常台区发生变化。基于台区现有电表采集的丰富电气量信息, 结合电气先验知识, 可利用对称相对熵模型实现表前分支线漏电用户定位。具体过程如图5所示。

1) 收集目标台区一个测量周期内漏电台区总表和用户电表的相关时序电气量数据。

2) 对时序数据进行预处理, 包括构建台区每个用户长时序最短供电路径方程, 采用多元线性回归法求解台区用户最短路径时序虚拟阻抗矩阵并按展平成一维矢量 $\dot{\mathbf{Z}}$ 输入对称相对熵模型。




图5 台区表前分支线漏电用户定位流程

Fig. 5 Flowchart of pre-meter leakage user localization in LVDS

- 3) 根据式(10)和(11)分别计算 $\hat{Z}$ 的邻近关联 A_L 和全局关联 G_L , 采用式(12)对称相对熵量化正常与漏电用户两种关联分布之间的特征差异。
- 4) 构建式(13)重构损失函数, 采用式(14)两阶段对抗机制进一步优化重构损失函数。
- 5) 基于模型重构损失和对称相对熵, 采用式(15)协同异常评分机制输出每个用户的异常得分, 标记超出设定阈值 δ 的嫌疑用户, 针对嫌疑用户进行现场巡线消缺工作, 并结合台区剩余电流大小决定是否需要重新迭代模型。

4 算例分析

4.1 低压台区仿真工况设定

如图6所示, 仿真模型采用IEEE公开数据集欧洲低压馈线测试系统 (the IEEE european low voltage test feeder), 该系统为三相四线制呈辐射状分布的低压配电

网, 三相变压器采用 Dyn11 接线方式, 额定容量为 0.8 MVA, 额定变比为 11/0.4 kV, 系统总共包含有 906 个节点和 55 个不同相别的单相负载, 每个负载的时序负荷可从数据集包含的 100 个 1 min 级别的 24 h 时序负荷数据表中任意选取后导入网络 (默认选取前 55 个负荷数据表)^[23], 负载的功率因数大小设置为在 0.85 ~ 0.95 随机取数。

为缩短数据处理和模型训练的时间, 采用文献[24]提供的简化方法, 即在保留原有变压器、线路和 55 个负载等其他元件参数不变情况下, 通过聚合无负载节点, 保留所有负载节点的拓扑位置和电气特性, 同时合并具有相同线路配置的无负载支路, 进一步将 906 个节点优化至 116 节点, 并在 Python 平台上利用 Pandapower 库搭建图6所示的低压配电网模型。




图6 IEEE 欧洲低压馈线测试系统

Fig. 6 IEEE European low-voltage feeder test system

为验证仿真平台所搭拓扑优化模型的有效性, 取源数据集中提供的 5、73 和 114 号单相用户的 OpenDSS 平台时序电流 1 440 min 三相潮流仿真结果 (906 节点) 与台区模型潮流结果 (116 节点) 作误差对比。具体误差分布如图7所示, 潮流仿真的最大误差值 < 0.2%, 表明两种仿真平台潮流计算结果差异极小, 表明优化后的网络在稳态潮流层面与原始网络具有高度一致性, 从根本上保证了后续暂态仿真中故障特征量的物理真实性。特别地, 在表前分支线漏电模拟实验中, 故障特征的产生与传播主要依赖于负载节点的接地阻抗参数及相邻线路的电气耦合关系, 而这些核心参数在优化过程中均未发生改变。因此, 可以认为该拓扑优化过程在保证计算效率的同时, 未对模型用户节点定位精度产生实质性影响。

需要注意的是, 由于所提漏电定位模型为纯数据驱动方法, 其定位精度主要依赖于故障工况下各监测节点的电气量测特征分布。在优化过程中, 拓扑简化严格保




图 7 Pandapower 简化模型潮流计算结果误差对比
Fig. 7 Comparison of power flow calculation errors for simplified Pandapower models

留了所有负载节点的电气连接关系与动态阻抗特性,确保关键负载节点的电气时序特征与原始网络具有等效性。尽管无负载支路的聚合会消除部分冗余拓扑信息,但此类节点本身不参与漏电流特征的形成与传播,因此不会影响模型对漏电故障特征模式的学习能力。

为确保后续仿真结果的真实性和严谨性,在不改变台区模型参数的情况,采用 IEEE STD 112-1991 方法计算三相电压不平衡度并绘制如图 8 所示时序变化曲线图。

具体计算公式如式(19)所示。

$$\varepsilon_U = \frac{\max \{ |U_A - U_{ave}|, |U_B - U_{ave}|, |U_C - U_{ave}| \}}{U_{ave}} \quad (19)$$

式中: U_A 、 U_B 和 U_C 分别为 A、B、C 三相电压的有效值, U_{ave} 为三相电压有效值的平均值。




图 8 IEEE 低压台区三相不平衡度

Fig. 8 Three-phase unbalance of the IEEE European low-voltage test feeder

4.2 表前漏电用户识别

1) 仿真环境和场景说明

仿真硬件配置环境 CPU 为 AMD Ryzen 7840HS, GPU 为 RTX 4060Ti, RAM 为 DDR5 双通道 32 GB, HDD 为 SDD 4 TB; 软件配置环境 OS 为 Windows 11 64 bit, Python 版本为 3.11.5, Git-bash 版本为 2.45.2。

训练集样本由 IEEE 欧洲低压馈线系统在模拟不同漏电场景下执行三相潮流计算后的 55 个用户构成,样本由漏电相别、漏电流大小、漏电点位置和漏电类型 4 种分类场景排列组合而成,每种场景组合可看作一个模拟台区。具体分类场景如表 1 所示。

表 1 样本所包含的所有漏电场景

Table 1 All leakage scenarios included in the samples			
漏电相别	漏电流大小	漏电点位置	漏电类型
A 相	低	台区上游	持续性漏电
B 相	中	台区中游	间歇性漏电
C 相	高	台区下游	

其中,漏电相别分为 A、B、C 三相;漏电点位置分为台区上中下游;漏电流大小参考树木搭线、户外设备绝缘受潮和架空线路搭接金属物等常见表前漏电场景,将漏电流大小分为低、中和高 3 种类别;A、B、C 三相漏电类型分为持续性和间歇性漏电,以此方式来模拟不同介质材料的绝缘特性差异以及干湿交替环境引发的接地阻抗时变特性,为模型训练提供了涵盖多物理场景耦合作用的典型样本,有效增强神经网络对台区复杂漏电工况的用户关联特征提取与泛化能力。为增强模型对不同程度漏电故障的识别能力,在构造样本时设置漏电电流范围为 [0.3 A, 20 A],以反映接地阻抗的典型变化区间。该取值区间的边界设定依据为:

$$\begin{cases} 0.3 \leq I_{low} < 1 \\ 1 \leq I_{med} < 5 \\ 5 \leq I_{high} \leq 20 \end{cases} \quad (20)$$

参考《GB 13955-2005 漏电保护器的基本要求》^[25], 低压配电系统中一级剩余电流保护动作值通常设定为 300 mA, 低于该值的剩余电流通常被视为台区自然剩余电流,不会引发保护动作,因此不具备典型漏电特征,不适宜纳入漏电样本,因此取 300 mA 作为下限。依据工程中如树枝搭线、金属接触、绝缘击穿等典型故障场景所导致的最大漏电流值选取 20 A 作为上限,根据欧姆定律估算,该区间对应的等效接地阻抗范围约为 [11 Ω, 733 Ω],可涵盖绝大多数低压台区可能出现的漏电阻抗变化情况。考虑到模型检测精度随漏电流增大而提高,且极大电流可能引发非线性放电过程并增加样本建模复杂度,故不

再设置更高上限。

2) 模型训练和测试

每种场景从图 6 拓扑结构中挑选上中下游若干处用户表前位置模拟表前漏电以保证足够数量的负样本,参照当前绝大多数电表采集频率为 15 min/次,测量周期为 1 天,设定分段大小为 96,总分段样本数量合计 24 750 个,将每一种场景按 7:3 比例划分训练集和测试集,初始学习率设置为 0.000 1,训练轮数设置为 3,早停机制(early stopping)设置为 3,隐藏层通道数设置为 512,自注意力头数设置为 8, α 大小设置为 3,预设值 r 大小设置为 1.82,输入与输出维度设置为 1。分别设置批次大小(batch size)为 16、32、64 和 128 训练模型,为防止过拟合,4 种配置下模型都在第 3 轮训练时达到早停计数上限后停止训练,4 种批次大小训练过程中损失迭代情况和评价指标结果如图 9 和表 2 所示。




图 9 不同批次大小重构损失和对称相对熵损失迭代变化
Fig. 9 Iterative changes of reconstruction loss and symmetric KL divergence loss with different batch sizes

表 2 模型评价指标结果

Table 2 Results of model evaluation indicators			
批次大小	准确率	召回率	F1 分数
16	0.888 3	0.918 2	0.903 0
32	0.919 6	0.976 0	0.947 0
64	0.920 9	0.951 5	0.935 9
128	0.895 9	0.957 6	0.925 8

4 种批次大小下损失随着迭代步数增加迅速收敛,表明模型逐步优化重构能力。批次大小设置为 16 时,对称相对熵损失收敛速度较慢,且波动较明显,随着批次大小增大,重构损失与对称相对熵损失的稳定性也显著提升,过大批次虽收敛速度较快,训练初期波动幅度较小,但灵活性较低。综合考虑模型收敛速度与稳定性之间的平衡及评价指标,选择批次大小为 32 作为最优调参。

3) 模型消融对比实验

为了证明所提模型的先进性和模型中每个模块对整体性能贡献的必要性,采用目前典型主流数据驱动类神经网络模型代替所提模型全局关联部分,即 Transformer 模型多头注意力模块,消融对比实验结果如表 3 所示。

以 Transformer+重构误差传统方法为基础,在自适应高斯核算法后,相较传统方法模型召回率提升了 31.76%,验证了选取自适应高斯核算法模块检测间歇性漏电的有效性;在此基础上进一步加入对抗优化策略,相较传统方法模型 $F1$ 分数分别提高了 23.32%,验证了对抗优化策略的有效性;继续将评判标准依次替换为相对熵和对称相对熵,模型 $F1$ 分数又分别提高了 11.50% 和 18.63%,验证了对称相对熵对于漏电故障特征提取的有效性;保持所提模型邻近关联、评判标准和优化策略不变,卷积神经网络(convolutional neural network, CNN)、长短期记忆网络(long short-term memory network, LSTM)、门控循环单元(gated recurrent unit, GRU)和图神经网络

表 3 模型消融对比实验

Table 3 Ablation study comparison of models							
场景序号	全局关联	邻近关联	评判标准	优化策略	准确率 δ_{ACC}	召回率 δ_{TPR}	F1 分数 δ_{F1}
1	Transformer	无	重构误差	无	0.497 1	0.561 8	0.527 5
2	Transformer	自适应高斯核	重构误差	无	0.462 0	0.879 4	0.605 8
3	Transformer	自适应高斯核	重构误差	对抗优化	0.709 0	0.820 4	0.760 7
4	Transformer	自适应高斯核	相对熵	对抗优化	0.867 4	0.884 2	0.875 7
5	Transformer	自适应高斯核	对称相对熵	对抗优化	0.919 6	0.976 0	0.947 0
6	CNN	自适应高斯核	对称相对熵	对抗优化	0.864 5	0.684 8	0.764 2
7	LSTM	自适应高斯核	对称相对熵	对抗优化	0.876 5	0.831 8	0.853 6
8	GRU	自适应高斯核	对称相对熵	对抗优化	0.802 2	0.753 3	0.777 0
9	GNN	自适应高斯核	对称相对熵	对抗优化	0.874 2	0.662 5	0.753 8

络(graph neural network, GNN)模型替换模型全局关联模块进行算法性能对比,对比结果显示 Transformer 模型表现最佳,验证了所提模型的优越性。

4.3 影响因素分析

工程实际中,常要求异常检测的准确性,而数据驱动类故障定位方法受制于数据采抄设备的数据采集质量,存在时间异步、量测误差、噪声等环境干扰。此外,若低压台区存在停电/空载居民用户,可能对所提模型特征阻抗的计算和模型定位精度产生影响。因此有必要对停电/空载用户场景和数据质量因素进行分析,研究其对模型定位精度的影响。

1) 停电/空载用户影响分析

在典型低压台区运行场景中,部分用户因停电、空载或接入负荷极小等情况,导致其电表电流长期处于极低值甚至为0,其中停电用户因其处于欠费断电状态,电表计量数据可能也为0或者缺失值(为保证特征阻抗计算方程能输出结果,在模拟停电用户时将其电压设置为 $220\text{ V}\pm5\%$)。该类用户在漏电故障定位中可能对式(6)特征阻抗的计算产生干扰,影响模型对异常用户的准确判别,因此有必要对上述情形下的模型性能重新进行评估。在原始用户数据集的基础上,干扰用户模拟配置如表4所示。

表4 干扰用户模拟配置

Table 4 Interference user simulation configuration			
干扰用户类别	时序电流/A	时序电压	模拟用户编号
停电用户	恒定为0	$220\text{ V}\pm5\%$	11号、50号、113号
空载用户	恒定为0	和原数据集一致	7号、34号、93号
极低负载用户	0.01~0.10	和原数据集一致	25号、62号、104号

分别计算台区中存在停电、空载和极低负载用户场景下的模型性能,并考虑这3类干扰用户是否还伴随表前分支线漏电的异常情况,绘制不同场景 ROC 曲线如图10所示。

对于这3类干扰用户(表前正常)场景及极低负载用户(表前异常)4种场景,模型 AUC 性能指标较好,均高于0.92。而对于空载/停电用户(表前异常)场景,模型定位精度大幅下降,表明该场景下分支线阻抗参数的缺失对台区用户虚拟阻抗的计算精度影响较大,导致模型无法准确捕捉异常关联特征,考虑到在工程实际中该场景发生概率较低,对所提方法的有效性影响较小。

2) 数据质量影响分析

低压台区用户电表的实际运行环境具有显著复杂性,其数据采抄过程易受多重因素干扰。具体而言,传感器性能波动、环境电磁干扰、信号传输失真及仪器计量精度等综合作用,常导致量测数据呈现时间异步性、




图10 不同干扰场景下模型 ROC 曲线对比

Fig. 10 Comparison of model ROC curve under different interference scenarios

系统误差及噪声干扰等质量问题,对数据分析可靠性构成挑战。

在噪声特征分析方面,工程实践中通常采用信噪比(SNR)作为量化指标,其典型取值范围为20~50 dB。为真实反映现场工况,本研究在台区15 min级量测数据基础上,叠加信噪比为20、35和50 dB的高斯白噪声,以此模拟复杂电磁环境下的典型噪声污染情况。关于量测精度,现行用户电表普遍符合1.0级精度标准,其理论量测误差应严格控制在 $\pm1\%$ 范围内。此外,依托于HPLC技术,其时钟同步精准管理水平亦较高,为研究可能存在的微小时间扰动问题对于所提模型定位精度的影响,设置同步采样时间偏差在 $\pm5\text{ s}$ 内。

在存在20、35和50 dB高斯白噪声的干扰下,分别计算加入 $\pm1\%$ 量测误差时、 $\pm5\text{ s}$ 同步采样时间偏差时以及同时存在两种数据质量问题时,对比原始正常数据集模型 AUC 可视化结果如图11所示。随着噪声比增加,各场景下模型 AUC 数值逐渐降低,在加入数据质量干扰后,相较于 $\pm1\%$ 量测误差, $\pm5\text{ s}$ 同步采样时间偏差对模型性能的影响较大,AUC 指标离群点的数量也明显增加,但各场景下 AUC 中位线数值仍保持0.90以上,表明模型对于此类数据质量问题具有一定的韧性,异常用户识别能力仍然能够得到保证。

4.4 实际台区泛用性验证

由于所构建模型基于无监督算法,依赖测量数据内在特征进行故障识别,无需依赖人工标注或特定台区结构训练。因此在不同台区中可直接应用,无需重新训练模型,具有良好的部署便捷性与实用性。为验证所提无监督模型在实际场景中的适用性与泛化能力,在湖南某市多个高损台区开展调研分析,结合每个台区杆变/箱变低压侧测量的剩余电流数据,选择某台区拓扑透明化建设试点应用县城中的某个高损台区(下面简称为A台




图 11 不同噪声干扰场景下数据质量影响对比

Fig. 11 Comparison of data quality in different noise interference scenarios

区)进行现场测试应用。A 台区服务运营处近期收到客户多次停电反馈,已将 RCD 退出,当地配电运维人员凌晨在台变低压侧测得剩余电流大小在 4 A 左右,但在每天中午时段漏电消失,运维人员结合台区线损情况推测为表前间歇性漏电故障。

按照图 5 流程图步骤,首先从用户信息采集系统中导出了 A 台区供带的 81 个用户近 1 个月的计量数据,将其中三相用户的数据拆解成 3 个不同相别的单相用户后,台区总单相用户数量为 117 户,将其依次用数字编

号。因系统中导出的大多数用户数据电表采抄频率为 1 h/次,将分段大小设置为 720,预设值 r 大小设置为 0.86,经模型计算后,40 号用户异常得分为 0.43,显著高于其他用户和阈值 δ 。将每个分段异常分数计算结果取平均值后可可视化如图 12 所示。

配电运维人员根据模型提供的辅助信息,遂在 40 号用户附近展开巡检,在其附近的杆塔地面拉线上,运维人员用验电笔测出了 113 V 的电压,在登杆后进一步观察时发现 40 号用户的接户线绝缘表层与杆塔高侧拉线处




图12 模型检测结果可视化

Fig. 12 Visualization of model inspection results

的金属抱箍疑似因摩擦导致电缆破皮现象,使得杆塔拉线向地面放电,将破皮点分离后拉线上电压消失,台变低压侧测得剩余电流 <300 mA,确认该台区漏电故障排除,验证了所提模型在未进行任何迁移或再训练的条件下,在实际工程场景中具备可移植性和有效性。

5 结 论

通过剖析台区用户表前分支线漏电故障发生时阻抗变化机理特征,并据此设计了符合工程实际的故障定位方法,结果表明所提模型可准确识别台区中的表前分支线漏电用户,具体工作总结为:

1) 分析指出每个用户与变压器之间存在唯一且最短的路径,该路径上的虚拟抗值在发生持续性或间歇性漏电故障时会发生明显变化而非正常情况时的相对稳定。

2) 基于台区用户之间固有的电气互联属性,提出邻近关联与全局关联之间对称相对熵模型来量化正常与漏电时的用户关联分布变化特征,采用对抗优化后的重构误差协同对称相对熵打分机制,在多种漏电场景样本集中训练后模型性能较其他同类算法表现最佳。

3) 在抗干扰实验中,模型对于存在停电/空载或数据质量问题的台区,模型仍然具备一定的韧性。在真实台区测试应用中,模型可准确识别实际台区中存在表前分支线漏电故障的用户,验证了模型的有效性,对于提升低压配电网运维工作效率和漏电故障消缺给予重要支撑作用。

低压台区用户表前线路漏电分台区主干线和表前分支线漏电两类,分支线仅承载单个或有限几个用户的负荷不同,干线承载更多用户的负荷,发生漏电故障时对用户影响更为复杂,问题求解更为困难,是下一步需要进行研究突破的目标。

参考文献

[1] 李天友, 徐丙垠, 薛永瑞, 等. 配电网触电保护技术[R]. 北京: 中国电机工程学会专题报告, 2018.

LI T Y, XU B Y, XUE Y R, et al. Electric shock protection technology of distribution network [R]. Beijing: Technical Reports on Selected Topic of CSEE, 2018.

[2] 杨智奇, 李天友, 陈航宇. 低压配电网的保护配置及其适应性分析[J]. 电气技术, 2020, 21(12): 40-44, 73.

YANG ZH Q, LI T Y, CHEN H Y. Analysis of protection characteristics and applicability of low-voltage distribution lines [J]. Electrical Engineering, 2020, 21(12): 40-44, 73.

[3] 高伟, 陈渊隆, 黄天富. 一种基于小波包分解和特征分量动态优选的剩余电流动作保护方法[J]. 仪器仪表学报, 2025, 46(1): 311-323.

GAO W, CHEN Y L, HUANG T F. A residual current protection method based on wavelet-packet decomposition and dynamic optimization of characteristic components [J]. Chinese Journal of Scientific Instrument, 2025, 46(1): 311-323.

[4] 金晟, 苏盛, 薛阳, 等. 数据驱动窃电检测方法综述与低误报率研究展望[J]. 电力系统自动化, 2022, 46(1): 3-14.

JIN SH, SU SH, XUE Y, et al. Review of data-driven electricity-theft detection methods and prospects for low false-positive rate [J]. Automation of Electric Power Systems, 2022, 46(1): 3-14.

[5] 戚成飞, 刘岩, 毕超然, 等. 数据驱动的低压配电网台区拓扑辨识技术综述[J]. 电力系统及其自动化学报, 2024, 36(10): 127-134.

QI CH F, LIU Y, BI CH R, et al. Overview of data-driven topology-identification techniques for low-voltage distribution substations [J]. Proceedings of the CSU-EPSA, 2024, 36(10): 127-134.

[6] 周凯欣, 冯萧飞, 苏盛, 等. 基于时序关联特性的错误接线漏电用户定位方法[J]. 仪器仪表学报, 2023, 44(10): 247-259.

ZHOU K X, FENG X F, SU SH, et al. User-location method for mis-wiring-induced leakage based on temporal association characteristics [J]. Chinese Journal of Scientific Instrument, 2023, 44(10): 247-259.

[7] 魏洪吉, 陈超强, 苏盛, 等. 基于计量数据超分辨率重构接线错误漏电用户快速定位方法[J]. 仪器仪表学报, 2025, 46(4): 88-101.

WEI H J, CHEN CH Q, SU SH, et al. Fast location of mis-wired leakage users via super-resolution reconstruction of metering data [J]. Chinese Journal of Scientific Instrument, 2025, 46(4): 88-101.

[8] 赖志强, 李彬, 李文松, 等. 基于台区剩余电流监测

- 的接线错误用户漏电故障定位[J]. 中国电机工程学报, 2024, 44(1): 85-95.
- LAI ZH Q, LI B, LI W S, et al. Leakage-fault location for mis-wired users based on residual-current monitoring in distribution-transformer service zones[J]. Proceedings of the CSEE, 2024, 44(1): 85-95.
- [9] 冯萧飞, 李彬, 苏盛, 等. 基于复数多元回归的低压用户接线错误漏电定位[J]. 中国电机工程学报, 2025, 45(9): 3472-3483.
- FENG X F, LI B, SU SH, et al. Location of low-voltage users with wiring faults based on complex multiple regression[J]. Proceedings of the CSEE, 2025, 45(9): 3472-3483.
- [10] 李碧恒, 李知艺, 鞠平. 基于随机矩阵理论的低压配电网边—云协同故障检测方法[J]. 中国电机工程学报, 2022, 42(1): 25-37.
- LI B H, LI ZH Y, JU P. Low-voltage distribution-network fault-detection method based on random-matrix theory for edge-cloud collaboration[J]. Proceedings of the CSEE, 2022, 42(1): 25-37.
- [11] 牟浩东. 低压线路泄漏电流监测与漏电保护技术研究[D]. 淄博: 山东理工大学, 2021.
- MOU H D. Research on leakage-current monitoring and leakage-protection technology for low-voltage lines[D]. Zibo: Shandong University of Technology, 2021.
- [12] 梁波, 姬广厚, 廉兴. 低压漏电故障判断和故障点查找方法[J]. 农村电工, 2017, 25(11): 31.
- LIANG B, JI G H, LIAN X. Method for judging low-voltage leakage faults and locating fault points[J]. Rural Electrician, 2017, 25(11): 31.
- [13] YANG Z D, ZHONG W H, LYU Q J, et al. Interaction-based inductive bias in graph neural networks: Enhancing protein-ligand binding affinity predictions from 3D structures[J/OL]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1-18[2024-04-15].
- [14] 蔡玉芳, 王涵, 李琦, 等. 联合自然梯度和AdamW算法的RSF图像分割模型[J]. 仪器仪表学报, 2023, 44(3): 261-270.
- CAI Y F, WANG H, LI Q, et al. RSF image-segmentation model combining natural-gradient and AdamW algorithm[J]. Chinese Journal of Scientific Instrument, 2023, 44(3): 261-270.
- [15] 王梓齐, 刘长良. 基于Box-Cox变换和对称相对熵残差分析的风电机组齿轮箱状态监测[J]. 中国电机工程学报, 2020, 40(13): 4210-4219.
- WANG Z Q, LIU CH L. Wind-turbine gearbox condition monitoring based on Box-Cox transformation and symmetric relative-entropy residual analysis[J]. Proceedings of the CSEE, 2020, 40(13): 4210-4219.
- [16] ANDRIAMANALIMANANA B, TEKEOGLU A, BEKIROGLU K, et al. Symmetric Kullback-Leibler divergence of softmaxed distributions for anomaly scores[C]. 2019 IEEE Conference on Communications and Network Security, 2019: 1-6.
- [17] 谭儒龙, 徐凯, 李国龙, 等. 基于数据集重构的主轴热误差半闭环建模方法[J]. 仪器仪表学报, 2024, 45(8): 227-234.
- TAN R L, XU K, LI G L, et al. Semi-closed-loop modeling of spindle thermal error based on dataset reconstruction[J]. Chinese Journal of Scientific Instrument, 2024, 45(8): 227-234.
- [18] 高学金, 吴浩宁, 高慧慧, 等. 基于一致损失生成对抗网络的冷水机组故障诊断[J]. 仪器仪表学报, 2025, 46(1): 285-297.
- GAO X J, WU H N, GAO H H, et al. Fault diagnosis of chillers based on a consistent-loss generative adversarial network[J]. Chinese Journal of Scientific Instrument, 2025, 46(1): 285-297.
- [19] 陈静, 郑垂铤, 李桂敏, 等. 考虑行业关联度的工业用户用电异常识别研究[J]. 仪器仪表学报, 2023, 44(4): 72-81.
- CHEN J, ZHENG CH D, LI G M, et al. Abnormal-electricity-usage identification for industrial users considering industry relevance[J]. Chinese Journal of Scientific Instrument, 2023, 44(4): 72-81.
- [20] 张承智, 肖先勇, 郑子萱. 基于实值深度置信网的用户侧窃电行为检测[J]. 电网技术, 2019, 43(3): 1083-1091.
- ZHANG CH ZH, XIAO X Y, ZHENG Z X. Electricity-theft detection on the customer side based on a real-valued deep belief network[J]. Power System Technology, 2019, 43(3): 1083-1091.
- [21] MUNIR M, SIDDIQUI S A, DENGEL A, et al. DeepAnT: A deep-learning approach for unsupervised anomaly detection in time series[J]. IEEE Access, 2019, 7: 1991-2005.
- [22] 高昂, 郑建勇, 梅飞, 等. 基于三元组孪生网络的窃电检测算法[J]. 中国电机工程学报, 2022, 42(11): 3975-3986.
- GAO ANG, ZHENG J Y, MEI F, et al. Electricity-theft detection algorithm based on a triplet network[J]. Proceedings of the CSEE, 2022, 42(11): 3975-3986.
- [23] SCHNEIDER K P, MATHER B A, PAL B C, et al. Analytic considerations and design basis for the IEEE distribution test feeders[J]. IEEE Transactions on Power Systems, 2018, 33(3): 3181-3188.

- [24] KHAN M A, HAYES B P. A reduced electrically-equivalent model of the IEEE European low-voltage test feeder[C]. 2022 IEEE Power & Energy Society General Meeting, 2022: 1-5.
- [25] 陈菽芳. GB 13955—2005《剩余电流动作保护装置安装和运行》有关说明[J]. 电力标准化与技术经济, 2006(4): 7-12.
- CHEN SH F. Explanation of GB 13955—2005 “installation and operation of residual-current operated protective devices” [J]. Electric Power Standardization and Technical Economics, 2006(4): 7-12.

作者简介



陈磊,2020年于长沙理工大学获得学士学位,现为长沙理工大学硕士研究生,主要研究方向为低压漏电故障定位。

E-mail:516901064@qq.com

Chen Lei received his B. Sc. degree from Changsha University of Science and Technology in 2020. Now he is a M. Sc. candidate at Changsha University of Science and Technology. His main research interest includes low-voltage leakage fault location.



苏华锋,2007年于清华大学获得学士学位,现为广东电网公司东莞供电局高级工程师,主要研究方向为配电网运维管理。

E-mail:shf03@126.com


Su Huafeng received his B. Sc. degree from Tsinghua University in 2007. Now he is a senior engineer in Dongguan Power Supply Bureau of Guangdong Power Grid Corporation. His main research interests include distribution network operation and maintenance management.



苏盛(通信作者),2002年于武汉大学获得硕士学位,2009年于华中科技大学获博士学位,现为长沙理工大学电气与信息工程学院教授,主要研究方向为基于配用电大数据的用电异常检测。

E-mail:susheng@163.com

Su Sheng (Corresponding author) received his M. Sc. degree from Wuhan University in 2002, received his Ph. D. degree from Huazhong University of Science and Technology in 2009. Now he is a professor at Changsha University of Science and Technology. His main research interests include power anomaly detection based on big data of power distribution and utilization.



冯萧飞,2021年于河南工业大学获得学士学位,现为长沙理工大学博士研究生,研究方向为低压漏电故障定位。

E-mail:1648529229@qq.com

Feng Xiaofei received his B. Sc. degree from Henan University of Technology in 2021. Now he is a doctoral student at Changsha University of Science and Technology. His research interest is fault location in LV system.



李彬,2019年于长沙理工大学获得硕士学位,现为长沙理工大学博士研究生,主要研究方向为配用电大数据分析和电力气象灾害分析。

E-mail:libin2021666@163.com

Li Bin received his M. Sc. degree from Changsha University of Science and Technology in 2019. Now he is a doctoral student at Changsha University of Science and Technology. His research interests include power distribution big data analysis and power meteorological disaster analysis.