

DOI: 10.19650/j.cnki.cjsi.J2513828

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

魏洪吉¹, 陈超强², 苏 盛¹, 邓 乐¹, 陈 凤²

(1. 长沙理工大学电气与信息工程学院 长沙 410014; 2. 国网湖南省电力公司长沙供电分公司 长沙 410004)

摘 要: 低压配电台区中用户零线、地线接线错误漏电故障多发, 易酿成人身触电伤亡事故。目前基于多元回归分析的方法虽已应用在定位接线错误漏电故障用户, 但受制于台区电流监测设备采样频率不足, 存在定位时效性差的固有缺陷。于是提出基于计量数据超分辨率重构的接线错误漏电用户快速定位方法, 通过实现低分辨率数据的重构, 突破传统方法在时间分辨率层面的技术瓶颈。首先分析接线错误漏电故障时台区剩余电流的构成, 明确台区剩余电流与用户负荷电流的关联特性。继而系统评估传统多元线性回归, Lasso 回归, 岭回归以及弹性网络回归模型的泛化性能差异, 揭示自变量共线性对参数估计稳定性的影响。进一步将时序电流数据映射为二维特征图像, 采用增强型超分辨率生成对抗网络 (ESRGAN) 模型进行超分辨率重构, 通过均方根误差、峰值信噪比与结构相似性指数多维度验证数据重构质量。最终使用重构的高分辨率数据建立弹性网络回归模型定位接线错误漏电用户。基于实验室仿真平台与现场实测数据的对比分析表明所提方法数据重构质量更高, 模型拟合程度和接线错误漏电用户定位准确率更高, 且故障定位时间与传统方法相比成倍数缩短。

关键词: 接线错误; 多元回归分析; 定位时效性; 数据重构; 生成对抗网络; 弹性网络回归模型

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

A fast location method for users with leakage current caused by wiring errors based on super-resolution reconstruction of metering data

Wei Hongji¹, Chen Chaoqiang², Su Sheng¹, Deng Le¹, Chen Feng²

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

2. State Grid Hunan Electric Power Company Changsha Power Supply Branch, Changsha 410004, China)

Abstract: In low-voltage distribution substations, users' neutral and ground wire wiring errors often cause leakage faults, which can easily lead to electric shock casualties. Although multivariate regression analysis has been used to locate users with wiring errors and leakage faults, it is limited by the insufficient sampling frequency of the current monitoring equipment in the substation area, and has the inherent defect of poor positioning timeliness. Therefore, a fast localization method based on super-resolution reconstruction of metering data is proposed. By reconstructing low-resolution data, this approach overcomes the time-resolution limitations of traditional methods. First, the composition of the residual current in the substation area during wiring errors and leakage faults is analyzed, and the correlation characteristics between the residual current and the user load currents are clarified. Then, the generalization performance of traditional multivariate linear regression, Lasso regression, ridge regression and elastic network regression models is systematically evaluated, revealing the impact of independent variable collinearity on the stability of parameter estimation. The time series current data is further mapped into a two-dimensional feature image, and the enhanced super-resolution generative adversarial network (ESRGAN) model is used for super-resolution reconstruction. The data reconstruction quality is verified by root mean square error, peak signal-to-noise ratio and structural similarity index. Finally, the reconstructed high-resolution data was used to establish an elastic network regression model to locate users with wiring errors and leakage. The comparative analysis based on the laboratory simulation platform and the field measured data showed that the proposed method has higher data reconstruction quality, higher model fitting degree and higher

accuracy in locating users with wiring errors and leakage. Moreover, the fault localization time is reduced by several multiples compared to traditional methods.

Keywords: wiring error; multiple regression analysis; positioning timeliness; data reconstruction; generative adversarial networks; elastic net regression model

0 引言

目前低压配电网漏电防护依赖于剩余电流保护装置(residual current device, RCD)和接地系统两道防线^[1],然而低压台区漏电故障多发,其中零线与地线接线错误是常见且隐蔽的故障类型,发生接线错误漏电故障会导致用户负荷电流通过地线流出,从而转化为台区剩余电流^[2],这种异常情况在用户用电时可能引发RCD的间歇性跳闸。

基于上述关联特性,文献[3]采用传统多元回归分析方法对接线错误漏电故障用户进行定位,文献[4]基于自适应Lasso回归模型,通过筛选不同故障场景下的可疑用户变量提高回归模型稳健性,文献[5]在多元回归分析和Lasso回归模型的基础上,构建基于卡尔曼滤波的状态空间模型定位接线错误漏电故障用户,文献[3-4]方法计算量小,易于实现,但在用户数量较多且变量存在多重共线性时定位精度显著下降。文献[5]在一定程度上克服了大规模台区漏电检测的挑战,但计算复杂度高,故障定位时间长,难以满足工程实际的快速检测需求。

回归分析可用于定位接线错误漏电故障用户,但要求量测数据数量明显多于台区用户数量才能准确定位。而低压配电台区用户数量较多,电表数据采集频率普遍较低,低分辨率数据采样频率通常为15~60 min级,对常规两三百用户的台区进行漏电故障用户定位时,使用15 min级频度量测数据也至少需要将近3天的监测数据才能准确定位^[6],这直接导致了其定位的时效性较差,无法及时发现漏电故障。针对上述问题,通过提高时序数据的分辨率,可有效降低数据采集周期对故障定位的限制,增强故障检测的时效性。

传统数据重构的方法主要包括插值方法如线性插值^[7],克里金插值^[8]与机器学习方法如Transformer^[9],长短期记忆网络(long short-term memory, LSTM)^[10]。插值方法易于实现但其重构精度较低,机器学习方法在重构精度上有所提升但模型的泛化能力受到限制。近年来,基于数据驱动的深度学习方法因其较少的模型假设和强大的拟合及泛化能力,已成为重构数据的常用方法。从低时间分辨率数据重构高时间分辨率数据的重构方法,其原理与图像超分辨率重构基本相似。文献[11]提出一种基于多分辨率特征融合的任意尺度图像超分辨率重建模型,实现任意尺度的超分辨率重建。文献[12]提出

了一种基于坐标注意力机制的生成对抗网络(generative adversarial network based on coordinate attention mechanism, CSRGAN),进一步提高图像重构性能。文献[13]采用超分辨率生成对抗网络(super-resolution generative adversarial network, SRGAN),将采样频率为15 min级的电力系统量测数据重构为1 min级的高分辨率数据,提升了数据细粒度。

与传统的一维数据重构方法相比,SRGAN框架的优点在于可以使用多个通道处理数据,但仍有改进的空间。例如,可以改进SRGAN模型以在不降低数据重构精度的情况下大大减少训练时间。增强型超分辨率生成对抗网络(enhanced super-resolution generative adversarial network, ESRGAN)模型在SRGAN模型框架的基础上,引入了没有批量归一化的残差-残差密集块提高模型泛化能力和重构精度,减少模型计算复杂度和内存的使用。

首先分析接线错误漏电故障时台区剩余电流的构成,明确发生接线错误时台区剩余电流由接线错误用户负荷电流作为主要组成部分。在此基础上,可以将台区剩余电流作为因变量用户负荷电流作为自变量构建回归模型计算权重系数定位接线错误用户,接线错误用户权重系数会明显大于其他用户。然后对比传统多元线性回归,Lasso回归,岭回归以及弹性网络回归模型拟合泛化能力,弹性网络回归模型结合了Lasso回归和岭回归的优点,兼顾共线性的影响和特征的选择^[14],相较于传统的多元线性回归模型稳健性更强。进一步分析高分辨率数据对共线性以及接线错误用户定位时间的影响,指出高分辨率数据降低用户负荷电流共线性影响的同时还可以缩短漏电用户定位时间。最后将一维低分辨率时序数据映射为二维数据图像,采用ESRGAN对图像进行超分辨率处理,再将生成的高分辨率图像逆归一化为高分辨率时序数据,使用重构的高分辨率数据构建弹性网络回归模型计算权重系数实现接线错误用户的快速准确定位。

基于实验室仿真数据和湖南省长沙市某真实低压配电台区数据进行验证,实验结果表明,使用重构的高分辨率数据定位漏电用户不仅准确率更高,且定位时间成倍数缩短。

1 接线错误漏电问题分析

1.1 接线错误与剩余电流构成

低压台区用户零线地线反接是一种典型的电气故障,严重影响电气系统的安全性。如图1所示,以TT系

统为例,展示接线错误漏电故障的基本原理:在正常情况下,电气系统中的零线与地线分别连接至电源的中性点和地面,形成稳定的电流回路。然而,当零线与地线发生反接时,用户负荷电流不再通过零线回流至电源中性点,而是通过地线返回地面,从而形成异常的电流路径。这种反接现象会导致电气设备出现异常运行,显著增加触电风险,并可能导致剩余电流保护器频繁跳闸或无法正常投入使用,从而影响电气系统的稳定性和安全性。




图1 漏电故障原理

Fig. 1 Leakage fault principle

正常情况下台区剩余电流为系统自然剩余电流,当单用户接线错误导致漏电故障时,台区剩余电流由该用户负荷电流与系统自然剩余电流的矢量和组成。

$$\dot{I}_R = \dot{I}_d + \dot{I}_r \quad (1)$$

式中: $\dot{I}_R$ 为台区总剩余电流; $\dot{I}_d$ 为用户负荷电流; $\dot{I}_r$ 为系统自然剩余电流。

发生两用户接线错误漏电故障时,台区剩余电流会根据用户负荷电流的相位差不同有所不同。因此剩余电流的计算如式(2)所示。

$$\dot{I}_R = \dot{I}_{d,a,e} + \dot{I}_{d,b,f} + \dot{I}_r \quad (2)$$

式中: $\dot{I}_R$ 依旧为台区总剩余电流; a 和 b 代表不同接线错误漏电故障用户编号; e 和 f 代表用户所处相别。

在接线错误漏电故障的情况下,台区剩余电流的相位和幅值与接线错误漏电故障用户的负荷电流变化密切相关,呈现出与其负荷电流相应的动态变化特征。

1.2 弹性网络回归

在接线错误漏电故障发生时,接线错误用户的负荷电流对台区剩余电流的影响较大,正常用户的影响较小。可通过回归模型计算用户负荷电流的贡献程度。

传统的多元线性回归是一种基于多个自变量的线性回归分析方法,能够揭示各个自变量与因变量之间的线性关系^[15-16],其基本公式如式(3)所示。

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \cdots + \beta_N X_N + \varepsilon \quad (3)$$

式中: Y 是因变量; X_N 是自变量; β_0 是截距; β_N 是权重系数,表示每个自变量对因变量的影响程度; ε 是误差项,表示模型无法解释的部分。

为确保回归模型在电力用户数据分析中的有效性与稳健性,除引入误差项假设外,还需充分考虑实际台区特性对模型构建的影响。低压台区用户用电行为的高度趋同性会导致用户用电特征产生显著相关性,这种特征关联性可能引发多重共线性问题^[17],不仅会削弱回归系数的估计精度,更会导致模型泛化能力和鲁棒性显著下降。基于最小二乘法的参数估计作为传统回归分析的核心方法,其通过残差平方和最小化获得的参数估计量虽具有无偏性优势,但当面对高维电力用户数据时,极易因解释变量多重共线性导致过拟合现象,致使台区接线异常用户的辨识精度大幅降低。

为克服上述缺陷,可采用正则化约束的参数估计方法。目前主流的正则化技术包含L1范数约束的Lasso回归^[18]和L2范数约束的岭回归^[19]。前者通过特征选择实现稀疏解,后者通过参数收缩提升稳定性,二者均可有效改善高相关特征场景下的模型性能。

Lasso回归是一种基于线性回归的正则化回归模型,在最小化残差平方和的同时,额外引入自变量回归系数的L1范数惩罚项,强制回归系数的绝对和保持尽可能小。这种约束导致部分回归系数被压缩为0,从而起到变量筛选的作用。通过最小化目标函数来估计回归系数,目标函数如式(4)所示。

$$\hat{\beta} = \operatorname{argmin} \left(\frac{1}{2n} \|y - X\beta\|_2^2 + \lambda \|\beta\|_1 \right) \quad (4)$$

式中: $\|\beta\|_1$ 表示回归系数的L1范数; $\lambda \|\beta\|_1$ 是L1正则化项。

岭回归通过在最小二乘损失函数中引入回归系数的L2正则化项,以抑制回归系数的过度波动。岭回归的目标函数如式(5)所示。

$$\hat{\beta} = \operatorname{argmin} (\|y - X\beta\|_2^2 + \lambda \|\beta\|_2^2) \quad (5)$$

Lasso回归引入L1正则化,虽然具有较强的稀疏性控制能力,但当存在强共线性时,Lasso往往“随机”选择其中一个变量赋予非零系数,而忽略其他等价变量,导致变量选择不稳定;岭回归通过L2正则化压缩所有回归系数,但不会强制任何系数为0,因此无法进行变量筛选。

弹性网络回归模型结合了岭回归和Lasso回归的优点,兼顾共线性处理与特征选择^[20]。弹性网络回归的目标是最小化以下目标函数进而计算每个用户的回归系数,即:

$$\frac{1}{2n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 + \alpha \left(\frac{1-\lambda}{2} \sum_{j=1}^p \beta_j^2 + \lambda \sum_{j=1}^p |\beta_j| \right) \quad (6)$$

式中: y_i 为第 i 个样本的剩余电流观测值; β_j 为第 j 个用户电流数据的回归系数; α 为正则化强度; λ 控制L1正则化与L2正则化的比例。

弹性网络回归通过L2正则化对共线特征施加惩罚,从而平衡共线变量的回归系数;同时,L1正则化使不相

关或贡献较小的特征系数被压缩至 0, 实现特征筛选与共线性处理的同步进行。

2 高分辨率数据影响性分析

尽管弹性网络回归模型相较于传统回归方法在多重共线性场景下展现出更强的稳健性, 但其本质上仍未完全消除自变量相关结构导致的统计偏倚。该方法的改进机理在于通过 L1 范数稀疏化约束与 L2 范数收缩约束的凸组合, 对回归系数进行联合调控, 从而抑制参数估计值的过度膨胀与数值不稳定性。这种正则化策略仅从优化目标函数层面施加惩罚项, 未能根本性改变自变量相关矩阵的结构特性。因此, 从数据源头对共线性进行干预, 是一种更为积极的解决思路。

2.1 高分辨率数据影响共线性

多重共线性的数学本质源于自变量间的近似线性依赖关系, 致使回归模型无法有效解耦各解释变量对响应变量的独立边际效应^[21]。参数估计值不仅呈现数值不稳定性, 更伴随统计显著性弱化现象。

在电力用户群体负荷特征分析中, 负荷曲线形态的相似性构成多重共线性的重要成因。特别需要指出的是, 单纯延长数据采集周期 ($T_i \sim T_j$) 并不能本质改善用户间固有负荷关联。当用户群体具备相同的用电属性 (如居民负荷典型日曲线趋同) 时, 晨昏双峰负荷的相位同步性将持续维持自变量相关结构。通过提升时间分辨率, 如将 15 min 级的数据提升至 1 min 级甚至 1 s 级, 可获取负荷曲线中隐含的瞬态细节: 在一个 15 min 采样间隔内, 部分用户可能呈现随机变化特性, 而另一些则可能保持稳态运行。此类细粒度负荷动态蕴含非结构化的随机噪声, 通过打破用户负荷曲线的时空关联性, 可实现对自变量的共线性优化。

在多重共线性量化评估方面, 方差膨胀系数 (variance inflation factor, VIF) 是一种常用的量化多重共线性程度的指标。VIF 通过衡量每个自变量与其他自变量之间的线性相关性来评估多重共线性的严重程度。自变量与其他自变量之间的共线性越强, 对回归模型的稳定性和参数估计的准确性的影响越大。

$$VIF_i = \frac{1}{1 - R_i^2} \quad (7)$$

式中: R_i^2 是用回归模型将 X_i 表示为其余所有自变量的线性组合后得到的决定系数。

VIF 大于经验阈值 (通常取 10) 时, 通常表示自变量之间存在严重的多重共线性, 即该自变量可能与其他自变量高度相关, 导致其对回归模型的影响变得不稳定。而当 $VIF < 10$ 时, 表示自变量与其他自变量之间的相关性较低, 可以认为这些自变量之间不存在显著的多重共线

性。在实际分析中, 对于 $VIF > 10$ 的自变量, 需要特别关注, 并可以考虑采取相应的处理措施, 如去除该自变量或采用主成分分析等方法, 以减少共线性对模型的干扰, 从而提高模型的稳定性和参数估计的准确性。

部分用户 1 和 15 min 级电流数据计算的方差膨胀系数如图 2 所示, 其中横坐标为用户编号, 纵坐标为方差膨胀系数大小。




图2 方差膨胀系数对比

Fig. 2 Variance inflation factor comparison

基于不同时间分辨率的方差膨胀系数对比实验表明, 提升数据采集密度对多重共线性抑制具有显著正向效应。这一现象揭示了时间分辨率与多重共线性之间的相关关系, 高分辨率数据能够降低用户负荷电流之间的共线性程度。

2.2 高分辨率数据影响定位时间

考虑共线性的前提下, 采用弹性网络回归进行接线错误用户定位时, 当将 t 个用户的用电行为特征变量作为自变量构建回归模型时, 参数估计的统计可靠性要求观测样本量 n 满足 $n \gg t$ 的约束条件, 理想情况下样本数量应达到自变量的 2~5 倍。

电表数据采集频率的限制导致定位漏电用户时效性较差, 以 15 min 级为例, t 个用户构建模型定位接线错误用户时间成本可量化为:

$$T_1 = n \Delta t = 15n \quad (8)$$

将采样间隔缩短至 1 min 后, 等效样本量使建模所需最小时间缩短为:

$$T_2 = n \Delta t = n \quad (9)$$

式(8)和(9)表明, 该技术路径可实现定位时间显著缩短。

随着采样频率的增加, 海量数据存储与实时处理之间的矛盾日益尖锐。目前智能电表采集周期级别大多为 15 min 级、30 min 级和 1 h 级等, 只有少数电表采集周期达到 1 min 级。数据分辨率的增加让数据存储的压力和后期处理的计算复杂度也随之增加。目前的存储设备可能无法承受如此庞大的数据量^[22]。

为了有效应对这些问题,提出电气图像驱动的超分辨率协同定位的方法,将用户电流时序数据转化为电气图像,在数据图像基础上,进一步利用 ESRGAN 模型对低分辨率图像超分辨,再重构为高频电流数据。最后构建弹性网络回归模型计算权重系数缩短接线错误漏电用户定位时间,提高定位时效性。

3 电流数据升频重构

3.1 数据图像描述

数据图像是将电力用户负荷时序数据通过特定编码方式映射为二维像素图像,其中像素值对应归一化处理的量测值。在数据图像中,归一化的电流数据作为像素值存储在各个通道中^[23]。低时间分辨率电流数据和高分时间分辨率数据分别编码为低分辨率与高分率图像,作为 ESRGAN 模型的训练输入,以实现高分率数据的重构。重构数据通过超分辨率图像还原得到,其中每个颜色通道的像素值用与图像分辨率对应的二维矩阵形式表示。

实验仿真数据使用某地区 80 名用户的电流数据,分别包括 1 min 级高分率数据与 15 min 级低分辨率数据,数据涵盖连续 60 天的全天记录。1 min 级数据每用户每日包含 1 440 个数据点,15 min 级数据每用户每日包含 96 个数据点。两类数据的采集时间同步,以确保时间分辨率差异是唯一影响因素。

3.2 电气数据映射图像

1) 数据预处理

将数据转化为图像的过程实际上涉及到数据的形状变换和归一化处理。从直观角度来看,图像可以被认为是由像素组成的矩阵,而电流数据可以被视为一维的数组。如果将这些数据转换为图像,就需要在保持数据原始结构的基础上,把它们按一定规则填充进图像的二维数组中。

数据的原始数值可能在某个范围内,但是图像的像素值通常需要在 0~255 范围内。因此,需要对数据进行归一化处理。归一化的目的是确保了数据的最小值映射到 0,最大值映射到 255,中间的值也按比例分布。

为消除不同用户电流幅值差异的影响,所有数据先按每用户最大最小归一化处理,映射到区间 $[0, 255]$,即:

$$x' = \frac{255(x - x_{\min})}{x_{\max} - x_{\min}} \quad (10)$$

式中: x 为原始电流数据; x' 为归一化后的数据。

2) 一维数据映射为二维图形

为了将数据作为图像输入,需要将每个用户的数据从一维数组转化为二维数组。假设每个用户的数据集包

含 n 个数据点,数据将根据图像的形状进行重塑。具体而言,图像的形状可以是 $s \times s$,其中 $s \times s = n$,确保所有数据点都能适应新的二维矩阵。

为便于构建电气图像,通过在高频电流数据每 15 个点后插入 0 值或采用线性插值,使比例因子 r 调整为整数 4,该处理对低分辨率图像无影响。每 64 h 的电流数据被转换为一张电气图像,低分辨率的 $s = 16$,高分率的 $s \times r = 64$ 。

电气图像仅通过调整数据排列位置来改变其结构,时序数据的大小决定了图像的颜色深浅,而图像的纹理变化则反映了时序数据的变化趋势。根据电气图像,可以直观地评估高频细节的还原效果。将低分辨率和高分率用户电流数据使用 Python 中 PIL 库转化为灰度图像,灰度图像的像素值范围为 $[0, 255]$,其中 0 表示黑色,255 表示白色,中间值表示不同的灰度等级^[24]。将数据归一化后映射的部分二维图像如图 3 所示,左边是高分率图像,右边是相对应的低分辨率图像。




图 3 映射图像

Fig. 3 Mapping images

3) 增强型超分辨率生成对抗网络

在本部分中介绍 ESRGAN 模型及其如何用于超分辨率数据图像重构。首先概述 ESRGAN,然后说明损失函数以及 ESRGAN 模型的结构。

作为一种深度学习模型,SRGAN 在大量任务中展现出了较优性能,尤其是图像超分辨率方面^[25]。ESRGAN 是对 SRGAN 的改进,引入了残差-残差密集块(residual in

residual dense block, RRDB) 作为基本网络构建单元的同时让鉴别器预测相对真实性而不是绝对值,能够生成拥

有更锐利高频细节的超分辨率图像^[26]。SRGAN 其生成器基本框架结构如图4所示。




图4 生成器基本框架

Fig. 4 Generator basic framework

ESRGAN 相对于 SRGAN 对生成器主要做出了以下2点修改:

(1) 去除所有 BN 层:BN 层在训练阶段利用当前批次的均值和方差对特征进行标准化,而在测试阶段则采用整个训练集的统计均值与方差。当训练集与测试集在分布上存在较大差异时,这种方式可能导致性能下降。

(2) 使用 RRDB 替换原始的基本块。RRDB 结合了多级残差网络和密集连接。RRDB 比 SRGAN 的基本块具有更深的结构,更复杂的残差连接方式。

ESRGAN 的残差块组合如图5所示,图5为一个残差密集块的组成, β 为残差缩放参数。




图5 ESRGAN 生成器残差块

Fig. 5 ESRGAN generator residual block

在训练过程中,BN 层通过计算当前批次的均值与方差对特征进行标准化,而在测试阶段则依赖训练集的统计估计值。训练与测试数据在分布存在显著差异时,可能削弱模型的泛化能力。为提升训练稳定性与性能一致性,ESRGAN 模型中移除了 BN 层。同时所提出的 RRDB 采用比 SRGAN 中原始残差块更深、更复杂的结构^[27]。

ESRGAN 的生成器的损失函数是多个子损失的加权和,包括像素损失、感知损失和对抗损失,其数学表达式如式(11)所示。

$$L_G = L_{pixel} + \lambda_1 L_{perceptual} + \lambda_2 L_{GAN} \quad (11)$$

式中: L_{pixel} 是像素损失,用于保证生成图像的基础像素精度; $L_{perceptual}$ 是感知损失,用于增强生成图像的高级特征质量; L_{GAN} 是對抗损失; λ_1 和 λ_2 分别为感知损失和對抗损失的权重。

像素损失使用 L1 范数衡量生成图像与真实图像的逐像素差异,即:

$$L_{pixel} = \|x_{n,w,h}^{SR} - x_{n,w,h}^{HR}\|_1 \quad (12)$$

式中: x_n 代表第 n 个样本值; w 和 h 分别为每一个通道中矩阵的宽和高;SR 代表生成的高分辨率图像;HR 代表原始的高分辨率图像。

感知损失采用 VGG19 网络的特征图进行计算,即:

$$L_{perceptual} = \|\phi(x_{n,w,h}^{SR}) - \phi(x_{n,w,h}^{HR})\|_1 \quad (13)$$

式中: $\phi(\cdot)$ 表示 VGG19 网络的中间特征提取层。

對抗损失为:

$$L_{GAN} = E[\log(1 - D_r) + \log D_f] \quad (14)$$

$$D_r = \sigma(C(x_{n,w,h}^{HR}) - E[C(x_{n,w,h}^{SR})]) \quad (15)$$

$$D_f = \sigma(C(x_{n,w,h}^{SR}) - E[C(x_{n,w,h}^{HR})]) \quad (16)$$

式中: $C(\cdot)$ 为判别器输出的特征评分; $\sigma(\cdot)$ 为 Sigmoid 激活函数; $E(\cdot)$ 为期望值; D_r 为真实图像的相对真实度; D_f 为生成图像的相对真实度。

除了改进生成器结构外,ESRGAN 还增强了判别器。与标准判别器简单的判断单张图像是真是假不同的是,ESRGAN 的判别器采用相对判别器 (relativistic discriminator, RD) 直接比较真实图像和生成图像的真实程度,ESRGAN 的判别器如图6所示。

判别器的损失函数定义为:

$$L_D = E[\log D_r + \log(1 - D_f)] \quad (17)$$

式中: D_r 和 D_f 定义如式(15)和(16)所示。

在 ESRGAN 的對抗训练中,其核心思想是判别器不仅要判断单张图像的真假,更要评估真实图像相较于生成图像的真实度。为此,判别器会计算输入图像的特征评分,并通过批量内的期望特征评分构建相对真实度^[28]。当训练达到预定轮数或损失函数趋于收敛时,




图6 ESRGAN 判别器基本框架

Fig. 6 ESRGAN discriminator basic framework

所生成的超分辨率图像在概率分布上将逐渐接近真实高分辨图像的分布特性,这意味着生成器可以生成准确的完整样本。此种设计有效解决了传统 GAN 训练中判别器过强或生成器崩溃等问题,有助于增强生成图像的感知质量和结构细节。

ESRGAN 模型中生成器的 RRDB 块选择 23 个,残差块中激活函数统一使用 Leaky ReLU 函数。上采样方式为单次 Pixel Shuffle 放大。残差缩放参数 β 取 0.2,便于稳定训练。判别器由 8 个卷积层组成,逐步提取高阶特征并压缩空间维度。激活函数依然选择使用 Leaky ReLU 函数。

在利用 ESRGAN 模型对电流数据进行图像增强后,最终生成的图像可以被用作进一步分析的输入。然而,由于图像通常是一个二维矩阵,而原始数据则是一个一维数据序列。为了恢复原始数据,需要将二维图像数据展平为一维数组,然后进行逆归一化处理。逆归一化公式如式 (18) 所示。

$$x = \left(\frac{x'(x_{\max} - x_{\min})}{255} \right) + x_{\min} \quad (18)$$

通过上述操作,能够将图像数据恢复为适用于后续分析的一维数据序列。

数据重构的流程如图 7 所示,首先构建训练数据集,将低分辨率数据编码为低分辨率数据图像,原始高分辨率数据编码为高分辨率数据图像。其次将低分辨率数据图像输入到生成器,判别器接收原始高分辨率图像作为输入。最终生成器输出的重构图像可用于还原原始的高分辨率信息。

4 算例分析

仿真使用 3.1 节中提到的实验仿真数据,高分辨率图像与超分辨率图像边长为 64,低分辨率图像变长为 16,




图7 数据重构流程

Fig. 7 Data reconstruction flow

划分成 1 800 张高分辨率图像与 1 800 张低分辨率图像,按照 8:1 的比例划分训练集和测试集。迭代次数设为 2 000 次,每次迭代批次大小设为 32。使用 Adam 优化器,动量参数 β_1 取 0.9,平衡当前梯度与历史梯度,加速收敛, β_2 取 0.999,自适应调整学习率抑制梯度震荡。模型初始学习率设为 1×10^{-4} ,每 500 次迭代后学习率变为原来的 1/10。在配置 NVIDIA GeForce RTX 4060 GPU 和 CPU 为 12th Gen Intel(R) Core(TM) i5-12400F 的 PC 端使用 PyTorch 实现。

4.1 数据重构精度评估

1) 评估指标

为评估超分辨率重构数据的精度,分别从数据幅值误差、趋势结构相似性等多个角度进行综合评估。选取的评估指标包括均方根误差 (root mean square error, RMSE)、信号峰值信噪比 (peak signal-to-noise ratio, PSNR)、结构相似性指数 (structural similarity index, SSIM)^[29-30]。通过这些多维度的评估体系,全面反映重构数据的保真度与真实数据的一致性,为后续基于超分辨率数据的负荷识别与漏电定位分析提供可靠的数据基础。

均方根误差是最基本的误差评估指标,直接反映重构数据和原始数据之间的整体误差, RMSE 越小,说明重构数据却接近真实数据,公式如式(19)所示。

$$I_{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i)^2}$$

(19)

信号峰值信噪比常用于图像评估,可以用于评估超分辨率重构的有效性, PSNR 越高,表示重构数据与真实数据的差异越小。公式如式(20)所示。

$$I_{PSNR} = 10 \lg \frac{255^2}{\frac{1}{2} \sum_{w,h} (x_{n,w,h}^{HR} - x_{n,w,h}^{SR})^2}$$

(20)

结构相似性指数更关注图像的结构、趋势是否一致, SSIM 从图像组成的角度将图像信息定义为亮度、对比度和结构 3 个不同因素的组合,亮度通过图像的平均值进行估算,对比度则依赖标准差进行度量,而结构相似性则采用协方差作为评价依据。SSIM 范围值为[0,1],越接近 1,说明重构数据与真实数据的整体结构越相似。公式如式(21)所示。

$$I_{SSIM} = \frac{2\mu_{x_n^{HR}}\mu_{x_n^{SR}} + C_1}{\mu_{x_n^{HR}}^2 + \mu_{x_n^{SR}}^2 + C_1} \frac{2\sigma_{x_n^{HR}x_n^{SR}} + C_2}{\sigma_{x_n^{HR}}^2 + \sigma_{x_n^{SR}}^2 + C_2}$$

(21)

式中: I_{SSIM} 为 SSIM 值; μ 代表各自的平均值; σ 代表各自的标准差; C_1 和 C_2 为避免分母为 0 的常数。

2) 数据重构可视化

将验证集的电气图像还原为时序形式的电气测量数据,数据重构结果如图 8 所示。通过上述方法获得的重构曲线在整体趋势上与真实曲线较为一致,除少数峰谷值存在较大偏差外,整体重建表现较为理想。




图 8 数据重构结果

Fig. 8 Data reconstruction results

3) 不同方法数据重构指标对比

为验证所提方法重构数据的优越性,对传统线性插值、SRGAN、Transformer 和 CSRGAN 模型以及所提方法进行数据重构指标评估。根据式(19)~(21)计算结果如表 1 所示。

表 1 不同数据重构方法重构精度评价结果

Table 1 Evaluation results of reconstruction accuracy of different data reconstruction methods

指标	插值	SRGAN	CSRGAN	Transformer	ESRGAN
I_{RMSE}	0.85	0.69	0.66	0.42	0.33
I_{PSNR}	17.30	21.75	23.23	24.32	27.36
I_{SSIM}	0.76	0.82	0.91	0.93	0.96

在 RMSE 统计方面,上述方法的 RMSE 比其他方法都要小,显著提高了数据重构的精度,同时具有更高的峰值信噪比和结构相似性指数,重构精度最高。

4) 方差膨胀系数对比

为系统评估高分辨率数据对用户负荷电流共线性的抑制效果,根据式(7)计算 80 个用户的低分辨率数据及其重构后的高分辨率数据的 VIF 值。阈值设定为 10,计算结果如图 9 所示。




图 9 VIF 对比结果

Fig. 9 VIF comparison results

图 9 计算结果中高分辨率数据的 VIF 值相较于低分辨率数据明显降低,这表明提高时序数据的分辨率有效减弱用户负荷电流数据的共线性程度。因此,使用重构的高分辨率数据有助于提升定位接线错误漏电故障用户的可靠性。

4.2 接线错误漏电故障用户定位准确性检验

1) 仿真实验

使用 3.1 节 80 用户的电流数据,包括 60 天的 1 min 级高分辨率数据与 15 min 级低分辨率数据进行实验室仿真实验。

为了验证基于重构高频电流数据进行接线错误漏电故障用户定位的准确性,使用重构后的 1 min 级高分辨率数据构建弹性网络回归模型,计算各用户的权重系数。实验设置 3 种接线错误漏电故障场景:单用户,同相两用户和异相两用户接线错误场景,分别预设 19 号用户、36 和 50 号用户、16 和 37 号用户为漏电用户。所有实验均

在 Jupyter Notebook 平台实现,回归系数通过最小二乘法进行计算。

漏电故障场景下,故障用户零线、地线反接时其负荷电流全部转化为剩余电流,故障用户的权重系数明显高于正常用户。

求解的权重系数结果如图 10 和 11 所示。接线错误




图 10 高分辨率数据计算的权重系数

Fig. 10 Weight coefficients for high-resolution data calculations




图 11 低分辨率数据计算的权重系数

Fig. 11 Weight coefficients calculated for low-resolution data

实验结果表明,在单用户接线错误漏电故障及同相两用户接线错误漏电故障的情况下,无论是采用低分辨率数据还是重构后的高分辨率数据进行计算,19 号用户以及 36 和 50 号用户的权重系数均显著高于其他用户,实现了对漏电故障用户的精准定位。然而,在异相两用户接线错误漏电故障的情形下,仅使用重构的高分辨率数据分析能够成功定位 16 和 37 号漏电故障用户,低分辨率数据却无法实现有效定位。

使用重构的高分辨率数据构建弹性网络回归模型可以定位出 3 种漏电场景下的故障用户,但是使用低分辨率数据定位异相两用户接线错误结果并不理想。为了避免实验结果的偶然性,对原始数据集进行以下处理,并计算接线错误漏电故障用户的定位准确率。具体处理流程为:

(1) 单用户接线错误漏电故障场景:随机选取 80 个接线错误漏电故障用户,分别将这些用户的负荷电流数据与台区自然剩余电流数据相量叠加得到台区剩余电流数据,然后构建多元线性回归模型,求解用户的权重系数并计算接线错误漏电故障用户的定位准确率。

(2) 同相两用户接线错误漏电故障场景:在同一相的用户中随机选取两个用户作为同相接线错误漏电故障用户进行组合,重复此过程 80 次,组成 80 种不同的同相两用户接线错误漏电故障场景样本。此时台区剩余电流由两个用户负荷电流与台区自然剩余电流数据相量叠加得到。

(3) 异相两用户接线错误漏电故障场景:在不同相别的用户中随机选取两个用户作为异相接线错误漏电故障用户进行组合,执行与(2)相同的操作。

不同漏电故障场景下接线错误漏电故障用户的定位准确率计算结果如表 2 所示。

实验结果表明重构高分辨率数据相较于原始高分辨率数据在两用户接线错误漏电场景下定位准确率会稍微下降,但在实际应用中依旧比低分辨率数据可靠,牺牲了一定定位精度的同时换来显著缩短的定位时间。

上述现象的主要原因在于,当发生异相两用户接线错误时,用户负荷电流的相位差对台区剩余电流的幅值影响较为显著。相位差越大,台区剩余电流的幅值越小,

表 2 不同分辨率数据定位接线错误用户准确率
Table 2 User accuracy of locating wiring errors with different resolution data (%)

数据类型	接线错误漏电故障场景		
	单用户	同相两用户	异相两用户
低分辨率数据	100	97	90
原始高分辨率数据	100	100	98
重构高分辨率数据	100	99	96

此时用户负荷电流与台区剩余电流之间的关联性减弱,从而降低了基于回归模型的漏电故障用户定位准确率。相比之下,高分辨率数据能够更精细地捕捉电流的瞬时相位变化,而低分辨率数据由于采样间隔较大,可能会平滑掉相位差异的关键细节,导致模型难以有效区分异相接线错误用户的特征,从而影响故障诊断的准确性。

2) 回归模型误差指标对比

为了更全面地评估弹性网络回归模型在特征选择、共线性抑制、模型稳定性等方面的能力,为后续分析提供更加可靠的理论依据,对比弹性网络回归模型与其他的回归模型误差评价指标。选择的指标包括平均绝对误差 (mean absolute error, MAE), 决定系数 (r-squared, R^2) 以及调整后可决系数。

平均绝对误差求解公式如式 (22) 所示。

$$MAE = \frac{1}{n} \sum_{i=1}^n |x_i - \hat{x}_i|$$
 (22)

决定系数反映模型的解释能力,即自变量能解释因变量变化的比例,其值介于 0~1,值越接近 1 说明模型拟合效果越好。求解公式如式 (23) 所示。

$$R^2 = 1 - \frac{\sum_{i=1}^n (x_i - \hat{x}_i)^2}{\sum_{i=1}^n (x_i - \bar{x}_i)^2}$$
 (23)

在高维数据中,可决系数可能会随着加入更多变量而人为升高,因此使用调整后的可决系数来修正。求解公式如式 (24) 所示。

$$R_a^2 = 1 - \left(\frac{(1 - R^2)(n - 1)}{n - p - 1} \right)$$
 (24)

式中: n 是样本数; p 是自变量个数。

弹性网络回归模型, Lasso 回归模型, 岭回归模型和 XGBoost 模型误差指标计算结果如表 3 所示。

使用弹性网络回归模型计算用户负荷电流相关系数的平均绝对误差最小,模型拟合程度最好,传统的线性回归最差,而 Lasso 回归模型和岭回归模型处于中间水平,弹性网络回归模型具有较高的稳定性。

表 3 不同回归模型拟合精度评价结果
Table 3 Evaluation results of fitting accuracy of different regression models

误差指标	线性回归	Lasso	岭回归	XGBoost	弹性网络
MAE	0.33	0.18	0.15	0.12	0.07
R^2	0.87	0.92	0.94	0.95	0.98
R_a^2	0.86	0.91	0.93	0.94	0.97

4.3 接线错误漏电故障用户定位快速性检验

为验证重构高分辨率数据定位接线错误漏电故障用户的快速性,使用一天时间跨度内不同样本量的高分辨率数据构建弹性网络回归模型,并按照与上节数据相同处理的操作计算 3 种故障场景下接线错误漏电故障用户定位准确率。计算结果如图 12 所示。




图 12 不同样本数量定位准确率

Fig. 12 Positioning accuracy of different sample numbers

在接线错误漏电故障场景下,由于共线性影响模型计算的结果,前 n 个样本数量可能无法进行精确的定位,但是当样本数量充足时,准确率会随着样本数量的增多呈对数形式增长,模型拟合程度达到最优时准确率最高。单用户接线错误漏电场景下定位准确率最高,同相两用户接线错误漏电场景其次,异相两用户接线错误场景定位准确率最低。此时若选择使用 300 个样本构建弹性网络回归模型定位接线错误用户,不仅准确率高,而且由于使用的是 1 min 级高分辨率数据,此时定位时间仅需 5 h,使用 15 min 级低分辨率数据则至少需要 75 h,定位时间显著增加。

4.4 实验验证

为验证所提出的定位接线错误漏电用户的方法的有效性和快速性,在湖南省长沙市某实际低压台区进行了现场验证。该台区包含 127 个用户接入,其中 28 号用户和 109 号用户发生了接线错误漏电故障,用户负荷电流数据和低压台区剩余电流数据完善,具有代表性。此台区拓扑结构示意图如图 13 所示,其中方框房屋代表接线错误漏电用户。




图 13 低压台区拓扑结构

Fig. 13 The low voltage area topology

采集此台区用户负荷电流数据以及台区剩余电流数据,根据所提方法,将时序数据转化为图像,使用增强型超分辨率生成对抗网络模型对图像进行超分辨率,再将高分辨率图像转化为时序数据得到重构的高分辨率电流数据,使用 200 个高分辨率电流数据构建弹性网络回归模型,用户负荷电流数据作为自变量,台区剩余电流作为因变量,求解权重系数结果如图 14 所示。




图 14 权重系数

Fig. 14 Weight coefficient

若使用低分辨率电流数据构建回归模型,至少需要 130 个样本才能保证得到的回归系数不受用户负荷电流共线性影响的同时还是唯一解,使用低分辨率数据定位时间至少需要 32 h,使用高分辨率数据则可以在 4 h 内准确地定位漏电用户。

通过在实际低压配电台区的现场验证,本方法能够准确、高效地定位漏电用户。相比于仅依赖低分辨率电流数据构建回归模型的方法,本方法能够显著缩短漏电故障的定位时间,提高故障处理的时效性。

5 结 论

在电力系统低压台区,定位接线错误漏电故障用户的准确性和快速性一直是亟待解决的关键问题,尤其是

在实时数据获取和分析方面存在诸多限制的情况下。针对上述问题提出了一种基于计量数据超分辨重构接线错误漏电用户快速定位方法,其主要贡献为:

1) 回归方法在用户接线错误漏电故障定位中受到采集数据频率的限制,导致时效性较差,所提方法针对低压配电台区的电流数据,将低分辨率数据重构为高分辨率数据,突破了传统方法受数据采集频率限制的技术难题,提高了数据质量,从而增强了定位的准确性和快速性。

2) 本研究提出将一维电流时序数据映射为二维特征图像,再借助 ESRGAN 模型进行图像超分辨率处理和数据重构。ESRGAN 模型与 SRGAN 模型相比,通过去除所有 BN 层和引入 RRDB 作为基本块提高模型泛化能力,提高了数据重构的质量。

3) 以往研究主要依赖传统的多元回归分析进行故障定位,而本研究综合相应评估了传统多元线性回归、Lasso 回归、岭回归及弹性网络回归在该任务中的拟合泛化能力,发现弹性网络回归在处理共线性问题和特征选择方面具有更优性能,最终采用弹性网络模型结合重构数据实现更精准、更先进的接线错误漏电用户定位。

4) 本研究不仅在实验室半仿真平台上进行了方法验证,还结合实际低压配电台区的运行数据,对提出的方法进行对比评估。实验结果表明,该方法可显著缩短接线错误漏电用户定位时间,提高故障定位的准确性。

然而,该方法在实际应用中存在一定局限性,如模型重构过程对计算资源存在一定需求,可能影响实时处理能力。此外,当数据规模扩大或应用场景复杂度提高时,模型的计算资源需求可能进一步增加,对设备的存储提出更高要求。

未来研究可结合实时数据处理架构,并引入边缘计算优化计算资源分配,以提升模型的实时性和适用性。此外,可进一步探索自适应学习算法,使方法能够动态调整参数,以适应不同负荷特性的配电台区,从而更广泛地应用于复杂环境下的故障诊断与预测。

参考文献

- [1] 李奎,解晨雨,牛峰,等.考虑非线性特性的剩余电流互感器建模及其输出调理电路参数设计[J].中国电机工程学报,2022,42(10):3815-3826.
LI K, XIE CH Y, NIU F, et al. Modeling of residual current transformer considering nonlinear characteristics and parameter design of its output conditioning circuit[J]. Proceedings of the Chinese Society for Electrical Engineering, 2022, 42(10): 3815-3826.
- [2] 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/OL].中国电机工程学报,1-13[2025-04-04].
FENG X F, LI B, SU SH, et al. Low-voltage user wiring

- error leakage location based on complex multivariate regression [J/OL]. Proceedings of the CSEE, 1-13 [2025-04-04].
- [3] 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 of wiring error users based on residual current monitoring in distribution zones [J]. Proceedings of the Chinese Society for Electrical Engineering, 2024, 44(1): 85-95.
- [4] 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. Faulty wiring leakage user location method based on temporal correlation characteristics[J]. Chinese Journal of Scientific Instrument, 2023, 44(10): 247-259.
- [5] 向骊羽, 周义博, 苏盛, 等. 基于台区剩余电流关联性分析的接线错误漏电用户识别方法[J]. 电力系统自动化, 2024, 48(20): 191-199.
- XIANG L Y, ZHOU Y B, SU SH, et al. A method for identifying wiring error and leakage users based on correlation analysis of residual current in transformer areas[J]. Automation of Electric Power Systems, 2024, 48(20): 191-199.
- [6] 张耀, 吴一全, 陈慧娴. 基于深度学习的视觉同时定位与建图研究进展[J]. 仪器仪表学报, 2023, 44(7): 214-241.
- ZHANG Y, WU Y Q, CHEN H X. Research progress of simultaneous visual localization and mapping based on deep learning[J]. Chinese Journal of Scientific Instrument, 2023, 44(7): 214-241.
- [7] 林帆, 张耀, 东琦, 等. 基于分位数插值和深度自回归网络的光伏出力概率预测[J]. 电力系统自动化, 2023, 47(9): 79-87.
- LIN F, ZHANG Y, DONG Q, et al. Probabilistic forecasting of photovoltaic power output based on quantile interpolation and deep autoregressive networks [J]. Automation of Electric Power Systems, 2023, 47(9): 79-87.
- [8] 叶爽怡, 扈晓翔, 司小胜, 等. 采用滑动窗口与克里金插值算法的复杂系统可靠性评估方法[J]. 西安交通大学学报, 2023, 57(4): 171-179.
- YE SH Y, HU X X, SI X SH, et al. Reliability assessment method of complex systems based on sliding window and Kriging interpolation algorithm[J]. Journal of Xi'an Jiaotong University, 2023, 57(4): 171-179.
- [9] 王琦, 张涛, 徐超伟, 等. 多尺度注意力融合与视觉Transformer方法优化的电阻抗层析成像深度学习方法[J]. 仪器仪表学报, 2024, 45(7): 52-63.
- WANG Q, ZHANG T, XU CH W, et al. Deep learning method for electrical impedance tomography optimized by multi-scale attention fusion and visual Transformer method[J]. Chinese Journal of Scientific Instrument, 2024, 45(7): 52-63.
- [10] 邱子琪, 王立忠, 潘华林, 等. 基于LSTM的10 MW海上风力机故障传感器数据重构研究[J]. 太阳能学报, 2024, 45(12): 342-349.
- QIU Z Q, WANG L ZH, PAN H L, et al. Research on faulty sensor data reconstruction of 10 MW offshore wind turbines based on LSTM [J]. Acta Energiæ Solaris Sinica, 2024, 45(12): 342-349.
- [11] 范文卓, 吴涛, 许俊平, 等. 基于多分辨率特征融合的任意尺度图像超分辨率重建[J]. 计算机工程, 2023, 49(9): 217-225.
- FAN W ZH, WU T, XU J P, et al. Arbitrary-scale image super-resolution reconstruction based on multi-resolution feature fusion [J]. Computer Engineering, 2023, 49(9): 217-225.
- [12] 贺智明, 黄志成. 基于坐标注意力生成对抗网络的图像超分辨率重建[J]. 微电子学与计算机, 2023, 40(12): 35-44.
- HE ZH M, HUANG ZH CH. Image super-resolution reconstruction based on coordinate attention generative adversarial network[J]. Microelectronics and Computers, 2023, 40(12): 35-44.
- [13] 李富盛, 林丹, 余涛, 等. 基于改进生成式对抗网络的电气数据升频重建方法[J]. 电力系统自动化, 2022, 46(3): 105-112.
- LI F SH, LIN D, YU T, et al. Electrical data frequency-up conversion and reconstruction method based on improved generative adversarial network[J]. Automation of Electric Power Systems, 2022, 46(3): 105-112.
- [14] 刘正男, 王凤随, 付林军. 改进的联合型图像超分辨率重建算法[J]. 电子测量与仪器学报, 2020, 34(1): 111-120.
- LIU ZH N, WANG F S, FU L J. Improved joint image super-resolution reconstruction algorithm[J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(1): 111-120.
- [15] 魏新园, 钱牧云, 赵洋洋, 等. 基于正则化的机床热误差自适应稳健建模算法[J]. 仪器仪表学报, 2022,

- 43(5): 77-85.
- WEI X Y, QIAN M Y, ZHAO Y Y, et al. Adaptive robust modeling algorithm for machine tool thermal error based on regularization[J]. Chinese Journal of Scientific Instrument, 2022, 43(5): 77-85.
- [16] 杨茂, 贾梦琦, 张薇, 等. 基于功率重构和时序特性约束的长预见期光伏集群功率预测[J]. 电力系统自动化, 2024, 48(15): 102-111.
- YANG M, JIA M Q, ZHANG W, et al. Long-term photovoltaic cluster power forecasting based on power reconstruction and timing characteristic constraints[J]. Automation of Electric Power Systems, 2024, 48(15): 102-111.
- [17] 肖霞, 伍兴国. 线性回归中多重共线性的几何解释[J]. 统计与决策, 2021, 37(21): 46-51.
- XIAO X, WU X G. Geometric interpretation of multicollinearity in linear regression[J]. Statistics and Decision, 2021, 37(21): 46-51.
- [18] 唐滢淇, 董树锋, 朱承治, 等. 基于 Tri-Training-LASSO-BP 网络的静态电压稳定裕度在线预测方法[J]. 中国电机工程学报, 2020, 40(12): 3824-3835.
- TANG Y Q, DONG SH F, ZHU CH ZH, et al. Online prediction method of static voltage stability margin based on Tri-Training-LASSO-BP network[J]. Proceedings of the CSEE, 2020, 40(12): 3824-3835.
- [19] 赵寒亭, 张耀, 霍巍, 等. 基于纵向联邦学习的短期风电功率协同预测方法[J]. 电力系统自动化, 2023, 47(16): 44-53.
- ZHAO H T, ZHANG Y, HUO W, et al. Short-term wind power collaborative forecasting method based on longitudinal federated learning[J]. Automation of Electric Power Systems, 2023, 47(16): 44-53.
- [20] 姜瀚书, 李雨田, 刘著, 等. 基于改进弹性网络回归的电容式电压互感器误差状态预测[J]. 吉林电力, 2024, 52(3): 8-12.
- JIANG H SH, LI Y T, LIU ZH, et al. Error state prediction of capacitive voltage transformers based on improved elastic net regression[J]. Jilin Electric Power, 2024, 52(3): 8-12.
- [21] 张淑清, 要俊波, 张立国, 等. 基于改进深度稀疏自编码器及 FOA-ELM 的电力负荷预测[J]. 仪器仪表学报, 2020, 41(4): 49-57.
- ZHANG SH Q, YAO J B, ZHANG L G, et al. Power load forecasting based on improved deep sparse autoencoder and FOA-ELM[J]. Chinese Journal of Scientific Instrument, 2020, 41(4): 49-57.
- [22] 林佳颖, 栾文鹏, 余贻鑫, 等. AMI 量测用于配电网在线状态估计的可信度建模及分析[J]. 电网技术, 2018, 42(4): 1191-1200.
- LIN J Y, LUAN W P, YU Y X, et al. Reliability modeling and analysis of AMI measurements for online state estimation of distribution networks[J]. Power System Technology, 2018, 42(4): 1191-1200.
- [23] 梁栋, 刘啸宇, 曾林, 等. 基于潮流引导神经网络的配电网贝叶斯状态估计[J]. 高电压技术, 2024, 50(11): 4864-4874.
- LIANG D, LIU X Y, ZENG L, et al. Bayesian state estimation of distribution network based on power flow guided neural network[J]. High Voltage Engineering, 2024, 50(11): 4864-4874.
- [24] 肖雄, 肖宇雄, 张勇军, 等. 基于二维灰度图的数据增强方法在电机轴承故障诊断的应用研究[J]. 中国电机工程学报, 2021, 41(2): 738-749.
- XIAO X, XIAO Y X, ZHANG Y J, et al. Application of data augmentation method based on two-dimensional grayscale images in motor bearing fault diagnosis[J]. Proceedings of the CSEE, 2021, 41(2): 738-749.
- [25] 邵振国, 张承圣, 陈飞雄, 等. 生成对抗网络及其在电力系统中的应用综述[J]. 中国电机工程学报, 2023, 43(3): 987-1004.
- SHAO ZH G, ZHANG CH SH, CHEN F X, et al. A survey of generative adversarial networks and their applications in power systems[J]. Proceedings of the CSEE, 2023, 43(3): 987-1004.
- [26] RIFAI R, UTAMA P H, TASMARA A F, et al. Enhancing resolution of raster-scan photoacoustic imaging using enhanced super-resolution generative adversarial networks(ESRGAN)[J]. Journal of Physics: Conference Series, 2025, 2945(1): 012040.
- [27] 倪劼, 柳青远, 周莉. 利用改进的 Real-ESRGAN 模型进行历史图像超分辨率重建研究[J]. 信息与管理研究, 2025, 10(1): 65-77.
- NI J, LIU Q Y, ZHOU L. Research on historical image super-resolution reconstruction using improved Real-ESRGAN model[J]. Information and Management Research, 2025, 10(1): 65-77.
- [28] 胡雨航, 赵磊, 李恒, 等. 多特征选择与双向残差融合的无监督水下图像增强[J]. 电子测量与仪器学报, 2023, 37(9): 190-202.
- HU Y H, ZHAO L, LI H, et al. Unsupervised underwater image enhancement based on multi-feature

selection and bidirectional residual fusion[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(9): 190-202.

- [29] 鲁转侠, 华彩成, 冯健, 等. 基于深度卷积神经网络的频高图特征提取研究[J]. 地球物理学报, 2024, 67(9): 3290-3300.

LU ZH X, HUA C CH, FENG J, et al. Feature extraction of ionograms based on deep convolutional neural network [J]. Chinese Journal of Geophysics, 2024, 67(9): 3290-3300.

- [30] 赵洪山, 彭轶灏, 刘秉聪, 等. 基于边缘注意力生成对抗网络的电力设备热成像超分辨率重建[J]. 中国电机工程学报, 2022, 42(10): 3564-3573.

ZHAO H SH, PENG Y H, LIU B C, et al. Super-resolution reconstruction of power equipment thermal imaging based on edge attention generative adversarial network[J]. Proceedings of the CSEE, 2022, 42(10): 3564-3573.

作者简介



魏洪吉, 2023 年于华北水利水电大学获得学士学位, 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: 1622979410@qq.com

Wei Hongji received his B. Sc. degree from North China University of Water Resources and Electric Power in 2023. Now he is a M. Sc. candidate at Changsha University of Science and Technology. His main research interest includes low-voltage leakage fault location.



陈超强, 1997 年于武汉水利电力大学获得学士学位, 2001 年于武汉大学获得硕士学位, 现为国网长沙供电公司高级工程师, 主要研究方向为配电网运维管理。

E-mail: 905427810@qq.com

Chen Chaoqiang received his B. Sc. degree from Wuhan University of Water Conservancy and Electric Power in 1997, received his M. Sc. degree from Wuhan University in 2001. Now he is a senior engineer in State Grid Changsha Power Supply Company. His main research interests include distribution network operation and maintenance management.



苏盛, 1998 年于武汉水利电力大学获得学士学位, 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 received his B. Sc. degree from Wuhan University of Water Conservancy and Electric Power in 1998, 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.



邓乐(通信作者), 2014 年于华中科技大学获得学士学位, 2021 年于华中科技大学获得博士学位。现为长沙理工大学电气与信息工程学院电力系专任教师, 主要研究方向为电力设备故障感知。

E-mail: ledeng@csust.edu.cn

Deng Le (Corresponding author) received her B. Sc. degree from Huazhong University of Science and Technology in 2014, received her Ph. D. degree from Huazhong University of Science and Technology in 2021. Now she is currently a full-time teacher in the Department of Electric Power, School of Electrical and Information Engineering, Changsha University of Science and Technology. Her main research interest includes power equipment fault perception.



陈凤, 2001 年于长沙理工大学获得学士学位, 2021 年于湖南大学获得硕士学位。现为长沙供电公司高级工程师, 主要研究方向为配电网运行管理。

E-mail: 1242075418@qq.com

Chen Feng received her B. Sc. degree from Changsha University of Science and Technology in 2001, received her M. Sc. degree from Hunan University in 2021. Now she is currently a senior engineer in Changsha Power Supply Company. Her main research interest includes distribution network operation management.