

基于联合神经网络的用户窃电行为识别模型

刘现义¹, 石星昊¹, 蒋怡康¹, 潘秀敏¹, 曲乐², 黄锋²

(1. 国网山东省电力公司聊城供电公司, 山东 聊城 252000;

2. 国网山东省电力公司高唐县供电公司, 山东 聊城 252800)

摘要:针对窃电行为识别准确率低的问题,提出了基于联合神经网络的窃电行为识别模型。首先,对获取的用户用电数据进行处理,利用格拉姆角场方法对用户用电数据进行二维化处理。然后,针对不同维度的用电数据,提出了基于联合神经网络的用户窃电行为识别模型,利用卷积神经网络(CNN)和双向长短期记忆(BiLSTM)神经网络提取一维用电数据和二维用电数据特征。通过实例分析表明,提出的联合神经网络模型对窃电行为识别准确率达到90%以上,证明所建立的评估模型为解决窃电问题提供了一种切实可行的方案。

关键词:窃电行为;联合神经网络;数据挖掘

中图分类号:TM769 **文献标识码:**A **DOI:**10.19457/j.1001-2095.dqed24467

Recognition Model of User Electricity Stealing Behavior Based on Joint Neural Network

LIU Xianyi¹, SHI Xinghao¹, JIANG Yikang¹, PAN Xiumin¹, QU Le², HUANG Feng²

(1. State Grid Shandong Electric Power Company Liaocheng Power Supply Company, Liaocheng 252000,

Shandong, China; 2. State Grid Shandong Electric Power Company Gaotang County

Power Supply Company, Liaocheng 252800, Shandong, China)

Abstract: Aiming at the problem of low recognition accuracy of electricity stealing behavior, an electricity stealing behavior recognition model based on joint neural network was proposed. Firstly, the acquired user electricity consumption data was processed, and the user electricity consumption data was two-dimensionally processed by using the Gramian angular field method. Then, for the electricity consumption data of different dimensions, a user electricity stealing behavior recognition model based on the joint neural network was proposed, and the features of the one-dimensional electricity consumption data and the two-dimensional electricity consumption data were extracted by using the convolutional neural network(CNN) and the bidirectional long short-term memory(BiLSTM) neural network. The case analysis shows that the proposed joint neural network model has an accuracy rate of more than 90% for the recognition of electricity stealing behavior, which proves that the established evaluation model provides a practical solution to the electricity stealing problem.

Key words: electricity stealing behavior; joint neural network; data mining

截至2020年全社会用电量达68 449亿kW·h,同比增长8.5%^[1]。但随着用电量的增加,用户窃电行为日益猖獗,用户窃电行为的隐蔽性和专业性也越来越强,每年由窃电行为造成的经济损失近百亿元^[2]。传统的窃电检查以人工巡查为主,存在误报、漏报现象,且难以及时发现用户窃电行为,耗费大量的人力物力^[3]。随着智能电网建设的不断推进,智能终端的高频率数据采集为用

户窃电行为识别分析提供了数据基础^[4-5],基于数据驱动的窃电行为识别研究也逐渐兴起。因此,研究一种准确率更高的窃电行为识别模型对日益增加的窃电类型、减少电力公司的经济损失具有重要意义。

目前,针对窃电行为识别研究大多是基于数据驱动的检测方法^[6],常用的用户窃电行为识别方法主要有:聚类算法^[7]、分类方法^[8]和状态估计

方法^[9]。文献[10]利用K均值聚类算法(K-means clustering algorithm)对收集到的电力数据进行处理,但K-means聚类算法随机性的特点导致实验结果存在不一致的问题,难以准确识别用户窃电行为。文献[11]提出了基于指标加权的窃电行为分析模型,根据不同指标重要程度不同,赋予不同的权重,但用户用电数据中存在的错误数据或空白数据影响用户窃电行为的准确定位,并且该方法依赖于专家库的构建,存在主观性强的缺点,所以在实际使用时效果不佳。文献[12]利用支持向量机作为二元分类器对用户用电数据进行特征提取和优化,该方法可以有效识别用户的窃电行为。但支持向量机针对大规模训练样本时计算速度慢,且对噪声数据比较敏感,难以应用于数据量庞大的电力系统中。上述算法在不同的用电场景中都取得了一定的成效,但存在需要人工构造样本、信息挖掘能力不强和窃电行为识别准确率低的问题^[13]。

受限于单一模型的识别精度,学界开始通过模型融合的方式提升窃电检测的准确率。集成学习通过联合多个学习器构建一个强学习器,代表算法为引导聚集算法(bootstrap aggregating, Bagging)^[14]和提升方法(Boosting)^[15]。集成学习构建的强学习器具有单一学习器的优点和更好的泛化性能,但本质上并没有改变数据的输入模式^[16]。联合学习考虑不同影响因素的特征或不同模式下的输入数据,在训练时利用多输入通道融合不同的模型,同步进行参数优化和更新,进一步提高模型的识别效果^[9]。文献[17]构建长短期记忆网络-多层感知机(long short-term memory networks-multilayer perceptron, LSTM-MLP)联合模型对用户用电原始数据和时序数据进行处理,获取用电数据的多维度特征,可以有效提高窃电行为识别的准确率。文献[18]将用电数据进行分层处理,在融合多层次特征基础上,建立多层次用电信息识别模型,可以对窃电行为进行识别。考虑到用户用电行为的不规律性和时序相关性,直接将用电数据输入到模型中会忽略数据间的内在关联。文献[19]提出了具有强泛化能力的深宽模型,在挖掘用户用电数据周期性特征的基础上进行自动组合,可以有效识别窃电行为。上述模型仅是对多维度数据进行简单的堆叠,难以获取数据的深层特征。

通过图像识别技术提高时序分类模型的精

度也成为众多领域的一大研究热点,该方法本质上是利用多像素通道表征样本差异性,从而更好地获取时间序列的深层特征^[20]。为了准确识别用户窃电行为,文中从数据输入形式和特征提取方法两方面着手,提出了基于注意力机制优化联合神经网络的用户窃电行为识别模型。首先,对收集到的用电信息进行清洗和处理,将用电数据转换为图像化数据,为用户窃电行为识别模型提供数据支撑;然后,利用卷积神经网络(convolutional neural network, CNN)模型和双向长短期记忆(bidirectional long short-term memory, BiLSTM)神经网络分别获取用电数据的局部特征和序列特征,挖掘数据间的内在关联,最终实现用户窃电行为的准确识别。

1 用户用电数据分析

1.1 一维用电数据处理

窃电行为改变了用户原有电量趋势的周期性特征。当电量趋势发生异常需要量化电量趋势,公式如下:

$$k_i = \sum_{l=r-d}^{r-1} \alpha_r \times \frac{g_r - g_l}{g_l} + \sum_{l=r+1}^{r+d} \alpha_r \times \frac{g_l - g_r}{g_r} \quad (1)$$

式中: k_i 为电量下降量; g_r 为用电量; g_l 为附近日期用量; α_r 为比重; r 为用电周期; d 为用电天数。

统计某一天的电量下降趋势时,可以将这天的前后5 d区间的数据进行统计,利用最小二乘法计算这段时间的总体电量变化趋势:

$$k_i = \frac{\sum_{l=i-5}^{i+5} (f_l - \bar{f})(l - \bar{l})}{\sum_{l=i-5}^{i+5} (l - \bar{l})^2} \quad (2)$$

其中

$$\bar{f} = \frac{1}{11} \sum_{l=i-5}^{i+5} f_l$$

$$\bar{l} = \frac{1}{11} \sum_{l=i-5}^{i+5} l$$

式中: k_i 为第*i*天的电量趋势; f_l 为第*l*天的用电量。

若用电量趋势不断下降,则认为可能存在窃电行为,则当天比前一天用电量趋势减少的总天数为

$$D_i = \begin{cases} 1 & k_i < k_{i-1} \\ 0 & k_i \geq k_{i-1} \end{cases} \quad (3)$$

对用户用电数据中的电流、电压、功率数据

进行分析,计算电量不平衡率,计算公式为

$$\eta_{im} = \frac{|W_t - W_a|}{\max\{W_t, W_a\}} \quad (4)$$

式中: W_t 为理论上的电量; W_a 为实际测量电量。

对所有数据进行归一化表示,将数据限定在 $[0, 1]$ 区间内,用电数据归一化表示公式为

$$v'_i = \frac{v_i - v_{\min}}{v_{\max} - v_{\min}} \quad (5)$$

式中: v_i 为输入原始数据; v'_i 为标准化后的数据; v_{\max}, v_{\min} 分别为相应属性的最大值和最小值。

1.2 格拉姆角转换

为了更好地展示窃电前后的变化,本文选择使用格拉姆角对用户用电数据进行图转换处理。首先对长度为 n 的用户日用电量数据序列 $X = \{x_1, x_2, x_3, \dots, x_n\}$ 进行归一化处理,将数据映射在 $[-1, 1]$ 区间内,然后对用户日用电量数据序列进行编码处理,形成新的序列 $\hat{X} = \{\hat{x}_1, \hat{x}_2, \hat{x}_3, \dots, \hat{x}_n\}$, 公式为

$$\hat{x}_i = \frac{[x_i - \max(X)] + [x_i - \min(X)]}{\max(X) - \min(X)} \quad (6)$$

将所有时间序列用电数据转化为极坐标表示,利用余弦函数保留不同时间间隔内点 (i, j) 的相关性,对一维时间序列数据进行处理,公式为

$$GAF = \begin{bmatrix} \cos(\varphi_1 + \varphi_1) & \dots & \cos(\varphi_1 + \varphi_n) \\ \cos(\varphi_2 + \varphi_1) & \dots & \cos(\varphi_2 + \varphi_n) \\ \vdots & \dots & \vdots \\ \cos(\varphi_n + \varphi_1) & \dots & \cos(\varphi_n + \varphi_n) \end{bmatrix} \quad (7)$$

式中: GAF 为格拉姆转换值; $\varphi_1 \sim \varphi_n$ 为角度对应的数据映射。

经过格拉姆角图转换处理后,矩阵的每一个元素值都是其行索引与列索引角度和的余弦值。

将用户窃电场景分为3种:1)采用恒定的窃电系数模拟串入电阻降压(失压)场景或分流法窃电(失流)场景;2)采用一个设定的阈值来人为地减小电能表读数,模拟电能表受篡改的场景;3)通过数据置“0”模拟电压或电流回路开路的场景。按照连续或间歇性窃电划分共可得6种情景。正常用户与窃电用户窃电一维用电序列曲线及其对应的二维图像如图1、图2所示。图中, G_0 表示原始用电数据, $G_1 \sim G_3$ 及 $G_4 \sim G_6$ 分别表示连续和间歇性窃电场景。由图1、图2可知,用电数据在经过格拉姆角图像化之后,正常用电行为和窃电行为具有明显的差异。长期窃电用户虽在

一维数据曲线上仍具有一定的周期性,但通过格拉姆角图像化之后具有幅值上的变化,可以有效挖掘用户的窃电行为。




图1 一维用电曲线对比

Fig.1 Comparison of one-dimensional power consumption curves




图2 二维数据对比

Fig.2 Comparison of two-dimensional data

2 基于联合神经网络的用户窃电行为识别模型

本文从数据驱动的角度出发来判别电力用户是否存在窃电行为,本质上是在解决一个有监督的二分类问题。因此,文中提出基于联合神经网络的窃电检测方法,利用原始一维时间序列数据和由其转换而成的二维图像数据进行全局特征和深层次相关性特征的提取。窃电行为识别流程如图3所示。

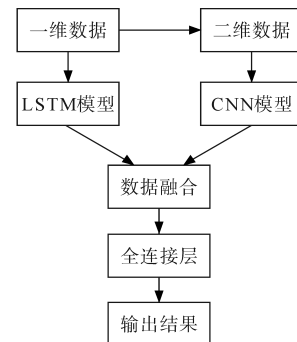


图3 窃电行为识别流程

Fig.3 Recognition process of electricity stealing behavior

下面将分别针对一维、二维以及融合处理模块进行详细介绍。

2.1 一维序列处理模块

传统神经网络在处理具有时序特征的用电数据时容易产生梯度爆炸问题。为了解决这一问题,文中采用LSTM对一维用户用电数据进行处理。LSTM模型在循环神经网络(recurrent neural network, RNN)模型的基础上加入了门控单元,可以在保留上下文信息的同时遗忘不重要的部分。

在 t 时刻,前向 LSTM 隐藏层的输出序列为 $\mathbf{h} = \{\mathbf{h}_1, \mathbf{h}_2, \dots, \mathbf{h}_n\}$, \mathbf{h}_1 的输入为 \mathbf{W}_1 , 从 \mathbf{h}_2 开始 $\forall \mathbf{h}_i \in \mathbf{h}$, 输入为 $\mathbf{W}_i \oplus \mathbf{h}_{i-1}$; t 时刻反向 LSTM 输出的隐状态序列 $\mathbf{s} = \{\mathbf{s}_1, \mathbf{s}_2, \dots, \mathbf{s}_n\}$, \mathbf{s}_1 的输入为 \mathbf{W}_1 , 从 \mathbf{s}_2 开始 $\forall \mathbf{s}_j \in \mathbf{s}$, 输入为 $\mathbf{W}_j \oplus \mathbf{s}_{j-1}$, 输出向量 $\mathbf{T}_k = \mathbf{h}_k \oplus \mathbf{W}_j \oplus \mathbf{s}_{j-1}$ 。LSTM 状态更新表达式如下:

$$\mathbf{a}_i^{(t)} = \text{sigmoid}(\mathbf{w}_i \mathbf{h}_{i-1} + \mathbf{u}_i \mathbf{x}_i + \mathbf{b}_i) \quad (8)$$

$$\mathbf{a}_f^{(t)} = \text{sigmoid}(\mathbf{w}_f \mathbf{h}_{i-1} + \mathbf{u}_f \mathbf{x}_i + \mathbf{b}_f) \quad (9)$$

$$\mathbf{a}_o^{(t)} = \text{sigmoid}(\mathbf{w}_o \mathbf{h}_{i-1} + \mathbf{u}_o \mathbf{x}_i + \mathbf{b}_o) \quad (10)$$

$$\mathbf{h}_i = \mathbf{a}_o^{(t)} \tanh(\mathbf{C}_i) \quad (11)$$

$$\mathbf{C}_i = \mathbf{a}_i^{(t)} \mathbf{C}_{i-1} + \mathbf{a}_f^{(t)} \tanh(\mathbf{w}_h \mathbf{h}_{i-1} + \mathbf{u}_h \mathbf{x}_i + \mathbf{b}_h) \quad (12)$$

式中: $\text{sigmoid}(\cdot)$ 函数、 $\tanh(\cdot)$ 函数均为激活函数; \mathbf{a}_y 为 LSTM 的门控单元, $y=i, f, o$; \mathbf{w}_y 为隐藏层权重矩阵; \mathbf{u}_y 为输入向量 \mathbf{x} 的权重矩阵; \mathbf{b} 为偏置项; \mathbf{C}_i 为 LSTM 单元 t 时刻的文本信息; 下角 i, f, o 分别表示输入门、遗忘门、输出门。

2.2 二维图像处理模块

二维图像处理模块是将用户用电数据二维化之后通过卷积核窗口进行卷积运算,通过深入分析得到抽象程度更高的特征卷积矩阵。但随着网络层数的增加,训练误差周期性扩大,神经网络准确率逐渐下降。残差网络在设计之初,在计算机视觉领域应用较多。通过加入残差学习使输出更加敏感,使得网络优化更加容易,残差网络模型如图4所示。

残差网络卷积块直接连接低层表示和高层




图4 残差网络模型

Fig.4 Residual network model

表示的特性,并通过边界填充保证正特性传输的一致。残差卷积块是由核大小为 S 的两个卷积层组成的非线性映射序列,残差卷积块中的第一层表达式如下:

$$\mathbf{b}_{i1} = f_{\text{ReLU}}(\mathbf{w}_1 \mathbf{b}_{i1+t-1} + \mathbf{c}_1) \quad (13)$$

式中: \mathbf{b}_{i1} 为卷积特征向量; \mathbf{c}_1 为偏置项; f_{ReLU} 为非线性函数; \mathbf{w}_1 为卷积层的卷积核; \mathbf{b}_{i1+t-1} 为残差处理的卷积块。

残差卷积块中的第二层表达式如下:

$$\mathbf{b}_{i2} = f_{\text{ReLU}}(\mathbf{w}_2 \mathbf{b}_{i2+t-1} + \mathbf{c}_2) \quad (14)$$

式中: \mathbf{b}_{i2} 为第二层卷积特征向量; \mathbf{c}_2 为偏置项; \mathbf{w}_2 为卷积层的卷积核, $\mathbf{w}_2 \in \mathbf{R}^{k \times 1}$ 。

通过残差学习优化之后,结合快速连接和逐元素添加相关操作,得到残差卷积块的输出向量 \mathbf{a} ,其中多次拼接残差卷积块的表达式如下:

$$\mathbf{b} = \mathbf{b}_{i1} + \mathbf{b}_{i2} \quad (15)$$

在池化层根据二维用电信息,卷积向量 \mathbf{c} 被分成了3部分 $\{\mathbf{b}_{i,1}, \mathbf{b}_{i,2}, \mathbf{b}_{i,3}\}$, 然后分别对3部分进行分段最大池化操作,公式如下:

$$N_{ij} = \max(\mathbf{b}_{ij}) \quad (16)$$

式中: \mathbf{b}_{ij} 为卷积特征向量。

将残差卷积块输出的结果在池化层进行3段池化,可以更好地进行二维用电数据特征提取,该过程返回每个段中的最大值,提高了关系的提取效率。依次对所有的卷积向量进行迭代,得到的最大值拼接成向量 $\mathbf{N}_{ij} = (N_{i,1}, N_{i,2}, N_{i,3})$, 然后将非线性函数应用到向量 \mathbf{N}_{ij} 中,最后分段最大池输出一个向量,即

$$\mathbf{h} = \tanh(\mathbf{N}_{ij}) \quad (17)$$

式中: \mathbf{h} 为最终得到的向量。

2.3 模块融合部分

上述一维序列处理模块和二维图像处理模块分别从一维时间序列及二维图像数据中提取用户用电行为的广度特征与深度特征。为了能让模型同时学习到这两类特征,对卷积模块及 BiLSTM 模块的输出进行拼接,以生成新的融合特征集合,拼接操作如下式所示:

$$\begin{aligned} T^{\text{joint}} &= f^{\text{joint}}(T^{1D}, T^{2D}) \\ &= [T^{1D} \quad T^{2D}] \\ &= [T_1^{1D} T_2^{1D}, \dots, T_m^{1D} \quad T_1^{2D} T_2^{2D}, \dots, T_n^{2D}] \end{aligned} \quad (18)$$

式中: 上角标 1D, 2D 分别表示变量信息的一、二维特征张量; T^{joint} 为拼接后的融合特征; T_i^{1D}, T_i^{2D} 分别为一维、二维特征张量的第 i 个元素; $f^{\text{joint}}(\cdot)$

为拼接函数,即将2个张量按照同一连接轴进行维度拼接; m, n 为连接轴处二者对应的维度。

为使混合模块能够公平地学习到来自双通道的特征信息,本文设置 n 和 m 均为128。拼接操作整合了卷积模块提取到的两类用电特征信息,再将这个新的集合输入神经元数量为64的全连接层进行非线性特征学习。此时,窃电概率大于0.5者判定为窃电用户,否则判定为正常用户。

3 实验分析

文中以某电网实际用电数据作为数据集,数据集中包含234 902条用电数据,经过筛选与清洗、归一化等处理后,选取等比例窃电样本数据与正常用电样本数据作为模型样本集,从模型样本集内分别随机抽取相应比例的数据构成训练集数据及测试集数据。评价指标如下:

1)准确率:表示正确分类的样本占总样本的比例^[12],计算如下:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (19)$$

式中: TP 为实际为正且被预测为正的样本数量; FN 为实际为正但被预测为负的样本的数量; FP 为实际为负但被预测为正的样本数量; TN 为实际为负且被预测为负的样本的数量。

2)精确率:表示实际正常样本占被分为正常样本的比例^[12],计算如下:

$$P = \frac{TP}{TP + FP} \quad (20)$$

3)召回率:表示所有正常样本中被正确识别为正常样本的比例^[12],计算如下:

$$R = \frac{TP}{TP + FN} \quad (21)$$

4) F 值:综合精确率和召回率的评价指标^[12],计算如下:

$$F = (2 \times P \times R) / (P + R) \quad (22)$$

为了更好地评估所提方法的性能,选择K-means^[10],BP(back propagation)^[11],支持向量机(support vector machine, SVM)^[12],多层感知器(multilayer perceptron, MLP)^[13],CNN^[14],WDNet(wide & deep)^[15]和随机森林与本文模型进行对比实验,对比结果如表1所示。

由表1可知,文中所提模型在4个性能指标上均优于其他传统的窃电检测模型,特别是在召回率指标上相较K-means高出了12.8%,这表明文

表1 模型对比

Tab.1 Model comparison

模型	准确率	召回率	F 值	ROC(准确率曲线)
K-means	0.896	0.755	0.764	0.921
BP	0.902	0.761	0.788	0.937
SVM	0.912	0.762	0.796	0.934
MLP	0.922	0.755	0.821	0.931
CNN	0.934	0.764	0.826	0.937
WDNet	0.937	0.781	0.835	0.942
随机森林	0.939	0.788	0.847	0.947
本文模型	0.955	0.866	0.895	0.964

中所提模型窃电行为的识别准确率最高,更适用于对准确率有要求的电力系统。如图5所示,在ROC对比上,文中所提模型表现最好,这是由于文中所提模型通过用电数据的二维化能更好地获取用户用电特征,通过与一维数据融合,能更全面地挖掘用户的窃电行为。




图5 ROC曲线对比

Fig.5 Comparison of ROC curves

如图6所示,以召回率 R 为横坐标,精确率 P 为纵坐标,曲线包含的面积越大表示模型效果越




图6 P-R曲线对比

Fig.6 Comparison of P-R curves

好。相比于其他模型,文中所提模型在 $P-R$ 图上优势明显,曲线包含的面积最大,是8种模型中右凸程度最明显的,模型性能最好。

经过联合神经网络算法分析得出的窃电用户经实地检查后确实存在窃电行为,与实际情况相同,如表2所示。

表2 用户窃电行为诊断结果

Tab.2 Comparison between diagnostic results and actual behavior of users electricity stealing

编号	用电量/(kW·h)	窃电日期	诊断结果
701 106 76	82.105	2020-09-11	正确诊断
342 234 53	86.450	2020-09-23	正确诊断
064 233 88	87.423	2020-09-27	正确诊断
102 034 75	97.420	2020-09-28	正确诊断
122 243 76	95.433	2020-11-03	正确诊断
006 435 56	87.462	2020-11-21	正确诊断
023 453 64	100.000	2020-11-26	正确诊断
143 091 06	89.453	2020-12-11	正确诊断
005 423 84	84.624	2020-12-15	正确诊断
064 447 74	87.826	2020-12-17	正确诊断
121 016 09	82.433	2020-12-23	正确诊断

由表2可知,文中所提模型诊断出的窃电行为经实地检查确实存在窃电行为,与实际情况相同。这表明窃电行为可以准确地被检测出来,文中所提模型更加适用于要求窃电行为检出率的实际业务场景。

4 结论

本文提出一种基于联合神经网络的窃电行为识别模型,利用卷积神经网络(CNN)和双向长短期记忆(BiLSTM)神经网络,对原始用电序列和基于图转换预处理后的二维用电图像进行特征提取,可以更好地获取用户用电特征,挖掘数据间的内在关联,进一步提升了窃电行为的检出率。未来将借助智能终端的信息获取能力,采集更多维度的输入信息来提升窃电模型的检测精度。

参考文献

[1] 张承智,肖先勇,郑子萱.基于实值深度置信网络的用户侧窃电行为检测[J].电网技术,2019,43(3):1083-1091.
ZHANG Chengzhi, XIAO Xianyong, ZHENG Zixuan. Electricity theft detection for customers in power utility based on real-valued deep belief network[J]. Power System Technology, 2019, 43(3):1083-1091.

[2] MATSUMOTO H, NEBA Y, ISHIZAKA K, et al. Comparison of

characteristics on planar contactless power transfer systems[J]. IEEE Transactions on Power Electronics, 2012, 27(6):2980-2993.

[3] 李植鹏,侯惠勇,蒋嗣凡,等.基于人工神经网络的线损计算及窃电分析[J].南方电网技术,2019,13(2):7-12,50.
LI Zhipeng, HOU Huiyong, JIANG Sifan, et al. Line loss calculation and electricity theft analysis based on artificial neural network[J]. Southern Power System Technology, 2019, 13(2):7-12, 50.

[4] 祝恩国,窦健.用电信息采集系统双向互动功能设计及关键技术[J].电力系统自动化,2015,39(17):62-67.
ZHU Enguo, DOU Jian. Design of two-way interaction function based on electricity information acquisition system and its key technology[J]. Automation of Electric Power Systems, 2015, 39(17):62-67.

[5] HOU Kaiyuan, SHAO Guanghui, WANG Haiming, et al. Research on practical power system stability analysis algorithm based on modified SVM[J]. Protection and Control of Modern Power Systems, 2018, 3(2):119-125.

[6] 史玉良,荣以平,朱伟义.基于用电特征分析的窃电行为识别方法[J].计算机研究与发展,2018,55(8):1599-1608.
SHI Yuliang, RONG Yiping, ZHU Weiyi. Stealing behavior recognition method based on electricity characteristics analysis [J]. Journal of Computer Research and Development, 2018, 55(8):1599-1608.

[7] 何艺,陈俊.基于GMDH算法的配电网线损数据预处理研究[J].电力系统保护与控制,2015,43(9):42-46.
HE Yi, CHEN Jun. Research on line loss data pretreatment in distribution network based on GMDH algorithm[J]. Power System Protection and Control, 2015, 43(9):42-46.

[8] 窦健,刘宣,卢继哲,等.基于用电信息采集大数据的防窃电方法研究[J].电测与仪表,2018,55(21):43-49.
DOU Jian, LIU Xuan, LU Jizhe, et al. Research on electricity anti-stealing method based on power consumption information acquisition and big data[J]. Electrical Measurement & Instrumentation, 2018, 55(21):43-49.

[9] 王庆宁,张东辉,孙香德,等.基于GA-BP神经网络的反窃电系统研究与应用[J].电测与仪表,2018,55(11):35-40.
WANG Qingning, ZHANG Donghui, SUN Xiangde, et al. Research and application of electricity anti-stealing system based on GA-BP neural network[J]. Electrical Measurement & Instrumentation, 2018, 55(11):35-40.

[10] 浦润琴,唐忠,王晓毅,等.恒压恒流型无线充电系统负载识别特性研究[J].电气传动,2020,50(9):123-128.
PU Runqin, TANG Zhong, WANG Xiaoyi, et al. Research on load identification characteristics of constant voltage constant current wireless charging system[J]. Electric Drive, 2020, 50(9):123-128.

[11] 吉昱营,张旭航.电动汽车充电系统的负载识别技术研究[J].电气传动,2020,50(1):109-112.
JI Yuying, ZHANG Xuhang. Research on load identification technology of electric vehicle charging system[J]. Electric Drive,

- 2020, 50(1): 109-112.
- [12] 李飞,王鸿玺,谭阿峰,等.考虑用电行为分析的电力用户用电预测研究[J].电子测量技术,2020,43(1):74-79.
LI Fei, WANG Hongxi, TAN Afeng, et al. Study on the power consumption forecast considering the analysis of power consumption behavior[J]. Electronic Measurement Technology, 2020, 43(1): 74-79.
- [13] 耿俊成,张小斐,周庆捷,等.基于局部离群点检测的低压台区用户窃电识别[J].电网与清洁能源,2019,35(11):30-36.
GENG Juncheng, ZHANG Xiaofei, ZHOU Qingjie, et al. A low voltage electricity theft identification method based on improved LOF[J]. Power System and Clean Energy, 2019, 35(11): 30-36.
- [14] 赵文仓,陈聪聪,郑鸿磊.基于LM算法的用户窃漏电行为预测[J].电子测量技术,2018,41(24):119-122.
ZHAO Wencang, CHEN Congcong, ZHENG Honglei. Prediction of user leakage behavior based on LM algorithm[J]. Electronic Measurement Technology, 2018, 41(24): 119-122.
- [15] 傅靖,季润阳,王栋,等.基于并行K-Means聚类的配电网台区用户行为分析模型研究及应用[J].电网与清洁能源,2018,34(11):71-76.
FU Jing, JI Runyang, WANG Dong, et al. Research and application of distribution network courts user's behavior analysis model based on parallel K-means clustering[J]. Power System and Clean Energy, 2018, 34(11): 71-76.
- [16] 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 Sheng, SU Sheng, XUE Yang, et al. Review on data-driven based electricity theft detection method and research prospect for low false positive rate[J]. Automation of Electric Power Systems, 2022, 46(1): 3-14.
- [17] 游文霞,申坤,杨楠,等.基于Bagging异质集成学习的窃电检测[J].电力系统自动化,2021,45(2):105-113.
YOU Wenxia, SHEN Kun, YANG Nan, et al. Electricity theft detection based on Bagging heterogeneous ensemble learning [J]. Automation of Electric Power Systems, 2021, 45(2): 105-113.
- [18] 高昆仑,杨帅,刘思言,等.基于一维卷积神经网络的电力系统暂态稳定评估[J].电力系统自动化,2019,43(12):18-26.
GAO Kunlun, YANG Shuai, LIU Siyan, et al. Transient stability assessment of power system based on one-dimensional convolutional neural network[J]. Automation of Electric Power Systems, 2019, 43(12): 18-26.
- [19] 张梦楠,李红娇.基于DCNN和SVC的窃电检测[J].计算机仿真,2022,39(6):92-97,429.
ZHANG Mengnan, LI Hongjiao. Electricity stealing detection based on DCNN and SVC[J]. Computer Simulation, 2022, 39(6): 92-97, 429.
- [20] 韩建富,肖春,宋小兵,等.基于GA-BP神经网络的能源互联网窃电行为识别方法[J].电气传动,2022,52(14):38-44.
HAN Jianfu, XIAO Chun, SONG Xiaobing, et al. An identification method of electricity theft on energy internet based on GA-BP neural network[J]. Electric Drive, 2022, 52(14): 38-44.

收稿日期:2022-07-07

修改稿日期:2022-08-04