



研究与开发

基于深度学习的智能电网窃电 检测混合模型研究

廖银玲¹, 李金灿¹, 王冰², 张君², 梁耀元²

(1. 广西电网有限责任公司, 广西 南宁 530023;

2. 广西电网有限责任公司梧州供电局, 广西 梧州 543002)

摘要: 针对传统窃电检测模型受维度诅咒、类不平衡等问题, 提出一种能有效检测智能电网窃电行为的混合深度学习模型, 利用深度学习卷积神经网络 (AlexNet) 处理维度诅咒问题, 显著提升数据处理的准确性; 通过自适应增强 (AdaBoost) 对正常和异常用电行为分类, 进一步提高分类精度; 使用欠采样技术解决类不平衡问题, 确保模型在各类数据的均衡性能; 利用人工蜂群算法对 AdaBoost 和 AlexNet 的超参数进行优化, 有效提高整体模型性能。使用真实智能电表数据集评估混合模型的有效性, 与同类模型相比, 提出的混合深度学习模型在准确率、精确度、召回率、F1 分数、马修斯相关系数 (MCC) 和曲线下面积-接收者操作特征曲线 (AUC-ROC) 分数上分别达到了 88%、86%、84%、85%、78% 和 91%, 不仅提高了用电行为监测的准确性, 也为电力系统的智能分析提供了新视角。

关键词: 深度学习卷积神经网络; 自适应增强; 深度驱动模型; 窃电检测; 特征提取

中图分类号: TM72

文献标志码: A

doi: 10.11959/j.issn.1000-0801.2024027

A hybrid model for smart grid theft detection based on deep learning

LIAO Yinling¹, LI Jincan¹, WANG Bing², ZHANG Jun², LIANG Yaoyuan²

1. Guangxi Power Grid Co., Ltd., Nanning 530023, China

2. Wuzhou Power Supply Bureau of Guangxi Power Grid Co., Ltd., Wuzhou 543002, China

Abstract: A hybrid deep learning model was proposed to effectively detect electricity theft in smart grids. The hybrid model employed a deep learning convolutional neural network (AlexNet) to tackle the curse of dimensionality, significantly enhancing data processing accuracy and efficiency. It further improved classification accuracy by differentiating between normal and abnormal electricity usage using adaptive boosting (AdaBoost). To resolve the issue of class imbalance, undersampling techniques were utilized, ensuring balanced performance across various data classes. Additionally, the artificial bee colony algorithm was used to optimize hyperparameters for both AdaBoost and AlexNet, effectively boosting overall model performance. The effectiveness of this hybrid model was evaluated using real smart meter datasets from an electricity company. Compared to similar models, this hybrid model achieves

accuracy, precision, recall, F1-score, Matthews correlation coefficient (MCC), and area under the curve-receiver operating characteristic curve (AUC-ROC) scores of 88%, 86%, 84%, 85%, 78%, and 91%, respectively. The proposed model not only increases the accuracy of electricity usage monitoring, but also offers a new perspective for intelligent analysis in power systems.

Key words: AlexNet, adaptive boosting, deep driven model, theft detection, feature extraction

0 引言

高级计量体系 (advanced measuring infrastructure, AMI) [1-2] 主要由智能电表、传感器、计算设备和现代通信技术组成, 用于消费者和电力公司之间的双向通信。随着互联网在 AMI 中的参与, 一些不法分子通过远程入侵智能电表系统和窃电对电网造成了损失, 因此检测窃电行为成为当前电网的重要需求。文献[3]提出一种基于状态的检测技术, 各种硬件组件, 如传感器、变压器以及智能电表, 集成后用于检测窃电行为, 但是需要额外的成本维护嵌入式设备。文献[4]提出涉及电力公司和窃电者的博弈论技术, 但该方法中效用函数的制定非常烦琐。智能电表的整合产生了大量数据, 为此文献[5]提出基于数据驱动的窃电检测, 利用机器学习 (machine learning, ML)、集合学习和深度学习 (deep learning, DL) 等数据驱动技术进行电网中的窃电检测 (electricity theft detection, ETD)。文献[6]采用卷积神经网络 (convolutional neural network, CNN) 进行 ETD, 通过欠采样技术和超采样技术检验所提模型的有效性, 用集合方法区分正常和异常样本。文献[7]提出了基于 CNN 和随机森林的混合 ETD 模型, 使用 CNN 模型对潜在特征进行有效提取。文献[8]结合聚类方法和统计技术, 开发了一种新的 ETD 技术来探索消费者的电力消费 (electricity consumption, EC) 档案, 通过最大信息系数法识别 EC 模式之间的关联性, 同时通过基于密度的聚类方法检测异常用电。

目前提出的窃电检测方案主要有以下局限性: 由于分类模型偏向于大类而忽略了小类而产

生概括性差和过度拟合的问题; 数据的多样性和维度在一定程度上会误导分类器; 一些非恶意因素的存在提高了监督学习模型分类的错误率, 造成假阳性率高进而导致分类模型混淆。

本文使用深度学习卷积神经网络 (deep learning convolutional neural network, AlexNet) 模型进行特征提取, 从 EC 数据中选择最合适的模型, 使用“近似缺失 (near miss, NM)”欠采样技术解决类的不平衡问题, 使用自适应增强模型 (adaptive boosting, AdaBoost) 对正常和异常的电力消费者进行分类, 使用人工蜂群 (artificial bee colony, ABC) 算法对所提出的 ETD 模型的超参数进行调整, 使用合适的指标如准确率、精确率、召回率、F1 分数、马修斯相关系数 (Matthews correlation coefficient, MCC) 以及曲线下面积-接收者操作特征曲线 (area under the curve-receiver operating characteristic curve, AUC-ROC) 来检查所提模型的有效性。

1 混合 DL 模型

本文提出的混合 DL 模型工作原理如图 1 所示, 它主要由以下几部分组成。

1.1 数据预处理

数据预处理的目的是在模型的训练和测试之前给数据一个标准化的结构。在该阶段进行各种数据预处理操作, 如处理缺失值、离群值和规范化数据。

1.1.1 处理缺失值

使用现场检查收集的实时智能表数据集, 它包含缺失值和噪声值。在大多数情况下, 数据中的缺失值以非数字 (NaN) 表示, 如果带




图1 混合DL模型工作原理

有缺失值的数据被输入 ML 或 DL 模型中，会降低它们的性能。本文利用线性插值（linear interpolation, LI）方法填补缺失值^[8]。LI 方法取第二天和前一天 EC 值的平均值，并相应地填补缺失值。

1.1.2 处理离群值

离群值是指与数据集中的其他观测值或数值

有明显不同行为的数值，离群值的出现干扰了分类模型的性能。本文利用 3σ 经验法处理离群值^[8]。

1.1.3 规范化数据

DL 模型在不同的数值范围内表现不佳，且数值对 DL 模型的学习过程有负面影响，同时会导致梯度爆炸问题，因此本文使用最小-最大归一化将特征值在 0 和 1 之间进行缩放。

1.2 类分布不均问题的解决

在执行 ETD 时,类分布不均是一个关键问题,实际生活中正常的电力消费者比非正常的消费者要多,这就造成了数据分布不平衡的问题,对监督学习模型的性能产生不利影响。此外,分类模型会向大类倾斜,而忽略了较小的类,这就产生了错误的结果。本文采用了一种欠采样技术来解决数据不平衡的问题。合成少数过采样技术(synthetic minority over-sampling technique, SMOTE)主要用于处理样本分布不均匀的问题,它以两个类的样本作为输入,生成少数类的合成样本,直到两个类的分布相等,但这种采样技术会产生过度拟合的问题,进而创建重复的记录。因此本文使用 NM 欠采样技术来解决类不平衡问题,这种技术能够智能地从较大的类中消除实例以均衡两个类的分布,它消除了那些靠近决策边界的点。NM 欠采样技术的工作原理如图 2 所示。具体步骤如下。

(1) 计算少数族裔和多数族裔的所有点之间的距离。

(2) 选择与较小类距离最小的实例,消除 n 个实例。

(3) 如果少数类有 m 个实例,算法返回多数类的 $m \times n$ 个实例。

NM 欠采样技术用来解决类不平衡问题的优

势在于,它帮助减轻模型对多数类的偏倚,提高对少数类的识别能力;在类不平衡的数据集上,尤其是在识别较少类别时,提升分类器的整体性能;通过减少样本的数量,降低模型训练和预测时的计算负担。

2 基于深度学习的集合模型

本文针对 ETD 提出的混合 DL 模型综合了 AlexNet 和 AdaBoost 的优点,且使用 ABC 算法为 AlexNet 和 AdaBoost 模型选择合适的超参数,具体如下。

2.1 提取特征的 AlexNet 模型

选择合适的 EC 特征是进行高效 ETD 的必要任务,因此本文利用 AlexNet 从消费者的资料中提取特征以减少传统模型^[9]的缺点。AlexNet 模型的基本结构如图 3 所示。

2.1.1 卷积层

卷积层对输入图像应用二维过滤器以提取和预测具有高相关性的特征。有研究表明周数据提取的特征相关度高,因此本文将 EC 数据转换为二维的周数据。

卷积层中各步骤的数学表示如下。

$$\text{Dim}(\text{inputshape}) = (n_h, n_w) \quad (1)$$

其中, n_h 表示特征, n_w 表示观察结果。




图 2 NM 欠采样技术的工作原理




图3 AlexNet 模型的基本结构

$$\text{Filter} = (f_w, f_h) \quad (2)$$

其中, f_w 、 f_h 分别表示过滤器的宽度和高度。输入形状与过滤器之间的卷积运算由式(3)描述^[10]。

$$\text{Conv}(\text{inputshape}, \text{filter}) = \sum_{i=1}^{n_h} \sum_{j=1}^{n_w} f_{ij} \quad (3)$$

卷积中的可学习过程由式(4)描述。

$$y_{\text{conv}}(X_i^{\text{ft}}) = \sigma \left(\sum_{\text{ft}=1}^{\text{ft}} W_i^{\text{ft}} * X_i^{\text{ft}} + b_i^{\text{ft}} \right) \quad (4)$$

其中, X_i^{ft} 为应用滤波器 f_i 后的输出特征图; W_i^{ft} 和 b_i^{ft} 为可学习参数, 用于描述权重和偏置因子; σ 表示整流后线性单元 (rectified linear unit, ReLU) 的激活; $*$ 是过滤器和特征之间的点积。

2.1.2 池化层

池化层在进行卷积操作后发生作用, 能够减少特征图的空间维度, 但不影响输入数据的原始分辨率, 此外还能克服计算量过大的问题。本文采用最大集合策略来减少 EC 数据的空间尺寸^[11], 最大集合策略只保留特征图中特定区域的最大值而摒弃剩余值。最大集合策略的工作机制如图 4 所示。




图4 最大集合策略的工作机制

最大集合策略的数学表达式为:

$$y^m = \max_{i,j} \in \mathbf{R}(y_{i,j}) \quad (5)$$

其中, y^m 表示最大集合策略的结果, i 和 j 分别表示第 i 卷积层和第 j 神经元。

2.1.3 激活函数

激活函数用于提取特征图, 采用 ReLU 作为每个卷积层后的激活函数, 该函数将负值转换为零, 并将剩余的值传递给接下来的卷积层 ReLU 函数的数学方程。

$$\text{ReLU} = \max(0, \text{value}) \quad (6)$$

2.1.4 Dropout 层

DL 模型对少数训练样本数据集的过拟合很敏感, 故本文引入随机失活 (dropout) 层使得单个神经网络可以用不同的架构来模拟, 通过

这些层激活隐藏层的神经元以克服过拟合和泛化不良问题。有研究表明, dropout 层平均激活率为 0~1, 当 dropout 率设置为 0.5 时, DL 模型的结果最佳。标准层和 dropout 层如图 5 所示, 表明了 dropout 操作前后神经元的激活和失活。




图 5 标准层和 dropout 层

2.1.5 完全连接层

在执行上述操作后, 特征图被转换为 1 维数据传递到神经网络中区分正常和恶意的数据。

2.1.6 全连接层

全连接层是 AlexNet 的最后一层^[12], 它将前几层的神经元与即将到来的神经元连接起来, 从提供的特征图中提取全局特征, 同时对前一层结果进行编译以进行最终分类。

全连接层的数学表达式为:

$$f_o = \sigma(W_l x_l + b_l) \quad (7)$$

其中, x_l 为输入特征向量, W_l 和 b_l 分别表示权重

和偏置因子, σ 表示 ReLU 函数, f_o 表示最终输出, 每次卷积后都使用 ReLU 来避免梯度消失的问题。

在本文提出的混合 DL 模型中, AlexNet 模型主要发挥以下作用。

(1) 特征提取: AlexNet 模型在本研究中起到关键的特征提取作用。AlexNet 模型在经过数据预处理后的数据中自动选择与问题相关的特征, 并有效地将噪声值的影响降到最低。

(2) 优化数据处理: AlexNet 模型在处理高维数据中具有较大的优势, 通过自动特征选择, 能够帮助减少不必要的特征, 从而避免维度诅咒问题。

(3) 提高模型准确性和效率: 自动筛选出最相关的特征, AlexNet 模型不仅提高了后续 AdaBoost 模型的准确性, 也提高了整个混合 DL 模型的效率。

2.2 作为分类器的 AdaBoost 模型

AlexNet 提取的特征被传给 AdaBoost 分类器, 该分类器使用集合方法区分正常和恶意的 EC 行为, 反复减少损失函数的值以提高独立的 ML 分类器的性能。AdaBoost 分类器的工作机制如图 6 所示。




图 6 AdaBoost 分类器的工作机制

AdaBoost 主要用于提高弱分类器的性能。弱分类器通常是指不够强大的分类器, 如 AlexNet 模型, 其无法单独很好地区分正常和恶意的电力消费行为。AdaBoost 组合多个弱分类器, 每个弱分类器都对数据进行一轮分类, 根据其分类性能对每个样本的重要性进行加权, 从而提高整体分



类器的性能。

AdaBoost 采用集合方法,通过组合多个分类器获得更强大的分类性能。在每一轮训练中,AdaBoost 调整每个样本的权重,使前一轮分类错误的样本在下一轮训练中获得更高的权重。使得 AdaBoost 更加关注那类难以分类的样本,以确保它们被正确分类。

AdaBoost 的目标是通过反复减少损失函数的值提高弱分类器的性能。损失函数用于衡量分类器在训练数据上的性能,AdaBoost 通过不断优化样本的权重和分类器的参数以最小化损失函数。这使得 AdaBoost 专注于改善之前分类错误的样本的分类能力。

AdaBoost 所组合的多个弱分类器可能是不同的 AlexNet 模型或在不同数据子集上训练的模型,通过投票或加权组合这些分类器的结果,它构建了一个更强大的分类器,可以更好地区分正常和恶意的电力消费行为。

2.3 对模型超参数进行调优的改进 ABC 算法

ABC 算法原理如图 7 所示,在改进的人工蜂群算法中,每只蜜蜂代表一个可能的解决方案(即一组超参数)。这些蜜蜂探索它们当前的解决方案周围区域,通过与邻近解决方案的比较来寻找更优的超参数组合。观察蜜蜂评估雇佣蜜蜂找到的解决方案,并选择更优的解决方案进行进一步的探索。如果一个解决方案在多次迭代中无法改进,侦察蜜蜂将被派出来在参数空间中随机搜索新的解决方案。这个过程的迭代可以显著提高超参数的优化效率,从而改进模型的整体性能。

与其他优化算法如粒子群优化 (particle swarm optimization, PSO) 算法和遗传算法 (genetic algorithm, GA) 相比,ABC 算法的控制参数较少^[13],能有效地处理随机成本目标函数,且收敛速度快。由于种群中的多样性较少,传统的 ABC 算法有过早收敛的问题。因此,本文采用的 ABC 算法引入

了一个认知学习因子 (cognitive learning factor, CLF) 的控制参数用于调节候选解的当前位置,这一改进减少了 ABC 过早收敛的问题。ETD 模型的工作原理如下。




图 7 ABC 算法原理

- (1) 数据预处理
- (2) NM
- (3) 最大最小归一化
- (4) 数据拆分
- (5) 将数据分为训练数据和测试数据
- (6) 使用 AlexNet 进行特征提取
- (7) 基于超参数调优进行二元分类

- i. 将特征传递给 AdaBoost 进行数据分类
- ii. 使用 ABC 算法后得到最佳调优集成模型

- (8) 损失计算

若损失最小, 转至步骤 (10); 反之转至步骤 (7)

- (9) 基准测试
- (10) 绩效评估

3 仿真分析

本文使用国网公司 2014—2016 年 42 372 名消费者的 EC 记录来验证本文所提模型的有效性,数据集见表 1。

表 1 数据集

描述	数值
用户总数	42 372
正常用户数	38 757
异常用户数	3 615
数据集大小	7 230
NM 前样本	38 757
NM 后样本	3 615

3.1 性能描述

AUC-ROC 度量是不平衡分类问题的重要指标,它计算正类和负类样本之间的差值,取值范围为 0~1。

$$AUC = \frac{\sum \text{Rank}_{i \in \text{positive class}} - \frac{S(1+T)}{2}}{S \times T} \quad (8)$$

其中, S 表示正类样本, T 表示负类样本,当 AUC 值为 1 时,分类模型表现较好。

$$REC = \frac{\text{真阳性}}{\text{真阳性} + \text{假阴性}} \quad (9)$$

$$PRE = \frac{\text{真阳性}}{\text{真阳性} + \text{假阳性}} \quad (10)$$

$$F1 \text{ 分数} = 2 \times \frac{PRE \times REC}{PRE + REC} \quad (11)$$

其中, PRE 和 REC 分别表示精确率和召回率。F1 分数用于衡量精确率和召回率之间的平衡比例,以更好地评价模型。

MCC 是另一个用于提供正面和负面预测之间相关性的性能指标。

$$MCC = \frac{TP \times TN - FP \times FN}{\sqrt{(TP+FP)(TP+FN)(TN+FP)(TN+FN)}} \quad (12)$$

其中, TP、FP、FN、TN 分别代表真阳性、假阳性、假阴性、真阴性。

3.2 不同模型及其仿真结果对比

支持向量机(support vector machine, SVM)^[14]、逻辑回归(logistic regression, LR)^[15]、AlexNet-AdaBoost-ABC 混合模型以及本文所提出模型后的分类结果见表 2,分析可知, SVM 在 NM 数据上的表现优于 SMOTE。然而它在所有基线模型上的表现不佳,原因在于 SVM 通过绘制 $(n-1)$ 个超平面来划分分类边界,由于 EC 数据的高维性,极大增加了 SVM 的计算负担,并且影响了 SVM 模型的收敛速度;采用 NM 数据平衡后 LR 模型的性能优于 SVM 模型,但与 SVM 相比,它在 SMOTE 中表现不佳。所提模型的准确度和损失曲线如图 8 所示。

从图 8 中可以看出,准确度曲线的上升和损失曲线的下降表明该模型能智能地学习,且收敛速度快。

表 2 不同模型分类结果对比

对比项	SMOTE				NM			
	SVM	LR	AlexNet-ABC	所提模型	SVM	LR	AlexNet-ABC	所提模型
精确率	0.64	0.58	0.75	0.77	0.65	0.68	0.86	0.93
召回率	0.60	0.45	0.80	0.82	0.61	0.64	0.84	0.84
准确度	0.58	0.41	0.77	0.80	0.60	0.67	0.88	0.88
F1 分数	0.38	0.29	0.78	0.81	0.40	0.66	0.85	0.88
MCC	0.52	0.20	0.62	0.62	0.39	0.42	0.78	0.78




图8 所提模型的准确度和损失曲线

所提分类器与其他分类器的 ROC 曲线如图 9 所示。从图 9 中可知,本文所提模型的 AUC-ROC 最高为 0.91。这表明该模型有效地区分了正类和负类样本。




图9 所提分类器与其他分类器的 ROC 曲线

所提模型与使用 SMOTE 和 NM 的其他模型性能对比分别如图 10、图 11 所示,从图 10 和图 11 中可知,与 SMOTE 相比使用 NM 的模型表现良好,这是因为 SMOTE 在一定阈值后产生重叠样本导致过拟合问题,而 NM 能从较大的类中删除重叠的样本。




图10 所提模型与使用 SMOTE 的其他模型性能对比




图11 所提模型与使用 NM 的其他模型性能对比

使用 NM 和 SMOTE 后所提模型与其他模型的 MCC 分数如图 12 所示。从图 12 中可知本文所提模型使用 NM 后 MCC 分数最高,这表明该模型成功地维持了正预测类和负预测类之间的相关性。




图12 使用 NM、SMOTE 后所提模型与其他模型的 MMC 分数

所提模型与其他模型的训练时间如图 13 所示。从图 13 中可知除 SVM 外,本文所提模型的计算时间最长为 48 s,复杂度均高于其他模型。这是因为 ABC 寻找最优的超参数子集需要额外时间。SVM 的计算时间最长为 64 s,这是因为它在处理非线性和高维数据上表现不佳。相比之下 LR 执行时间最短,因为它由单层神经网络组成,但 LR 性能最差,因为它无法从 EC 数据中捕获复杂的非线性数据。与其他模型相比 AlexNet 模型的计算复杂度高,因为该模型有额外的卷积层和最大集合层。




图13 所提模型与其他模型的训练时间

4 结束语

本文介绍了一种用于窃电检测的混合深度学习模型。该模型结合了 AlexNet、AdaBoost 和 ABC 算法,采用 AlexNet 模型处理高维问题,使用 AdaBoost 模型区分正常用户和异常用户,使用欠采样技术处理数据分布的不平衡问题,通过 NM 技术最小化大多数类样本来均衡类的比例,利用 ABC 算法对模型进行超参数调整,选择合适的性能指标来衡量所提出的 ETD 模型的有效性。结果表明,所提出的 ETD 模型优于其他模型,在准确率、精确率、召回率、F1 分数、MCC 和 AUC-ROC 分数上分别达到了较高的分数,具有一定的实用性。

参考文献:

- [1] 刘炜,王朝亮,肖涛,等. AMI数据驱动的电动汽车充电设施计量运行误差状态评估方法[J]. 电力自动化设备, 2022, 42(10): 70-76.
LIU W, WANG C L, XIAO T, et al. AMI data-driven state evaluation method for measurement operation error of electric vehicle charging facilities[J]. Electric Power Automation Equipment, 2022, 42(10): 70-76.
- [2] 白志霞,刘馨卉,索思远,等. 基于集群智能的智能电能表异常检测技术[J]. 电测与仪表, 2022, 59(1): 195-200.
BAI Z X, LIU X H, SUO S Y, et al. Anomaly detection technology based on swarm intelligence for smart meters[J]. Electrical Measurement & Instrumentation, 2022, 59(1): 195-200.
- [3] 曹德发,马明,汤平瑜,等. 多源量测环境下基于深度强化学习的配电网分布式状态估计方法[J]. 可再生能源, 2021, 39(10): 1414-1420.
CAO D F, MA M, TANG P Y, et al. Distributed state estimation method of distribution network based on deep reinforcement learning in multi source measurement environment[J]. Renewable Energy Resources, 2021, 39(10): 1414-1420.
- [4] AMIN S, SCHWARTZ G A, TEMBINE H. Incentives and security in electricity distribution networks[C]//International Conference on Decision and Game Theory for Security. Berlin,

- Heidelberg: Springer, 2012: 264-280.
- [5] 刘文浩,冯玥,姜东良. 基于AMI数据驱动的窃电用户识别研究[J]. 制造业自动化, 2022, 44(11): 5-8.
LIU W H, FENG Y, JIANG D L. Research on identification of electric theft customers based on AMI data drive[J]. Manufacturing Automation, 2022, 44(11): 5-8.
- [6] PEREIRA J, SARAIVA F. Convolutional neural network applied to detect electricity theft: a comparative study on unbalanced data handling techniques[J]. International Journal of Electrical Power & Energy Systems, 2021, (131): 107085.
- [7] 刘智慧. 基于并行 CNN-GRU 的高级量测体系网络入侵检测研究[D]. 大连: 大连理工大学, 2022.
LIU Z H. Research on network intrusion detection of advanced metering infrastructure based on parallel CNN-GRU[D]. Dalian: Dalian University of Technology, 2022.
- [8] 姚冬媛. 智能电网中的盗电检测技术研究[D]. 上海: 上海电力大学, 2019.
YAO D H. Research on detection detection technology of energy theft in smart grid[D]. Shanghai: Shanghai University of Electric Power, 2019.
- [9] 汪涛,梁瑞宇,黄虎,等. 基于多层多核卷积神经网络的非侵入式负荷监测方法研究[J]. 电子器件, 2021, 44(6): 1429-1435.
WANG T, LIANG R Y, HUANG H, et al. Research on non-intrusive load monitoring method based on multi-layer and multi-kernel convolution neural network[J]. Chinese Journal of Electron Devices, 2021, 44(6): 1429-1435.
- [10] 张玉天,邓春宇,刘沅昆,等. 基于卷积神经网络的非侵入负荷辨识算法[J]. 电网技术, 2020, 44(6): 2038-2044.
ZHANG Y T, DENG C Y, LIU Y K, et al. Non-intrusive load identification algorithm based on convolution neural network[J]. Power System Technology, 2020, 44(6): 2038-2044.
- [11] 徐先峰,赵依,刘状壮,等. 用于短期电力负荷预测的日负荷特性分类及特征集重构策略[J]. 电网技术, 2022, 46(4): 1548-1556.
XU X F, ZHAO Y, LIU Z Z, et al. Daily load characteristic classification and feature set reconstruction strategy for short-term power load forecasting[J]. Power System Technology, 2022, 46(4): 1548-1556.
- [12] 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.
ZHANG M N, LI H J. Electricity theft detection based on deep convolutional neural network and support vector classification[J]. Computer Simulation, 2022, 39(6): 92-97.
- [13] 齐言强. 基于蚁群算法伺服系统控制参数的研究应用[D]. 西安: 西安工程大学, 2018.
QI Y Q. Research and application of servo system control parameters based on ant colony algorithm[D]. Xi'an: Xi'an Polytechnic University, 2018.
- [14] 陈春玲,许童羽,郑伟,等. 多类分类SVM在电能质量扰动识别中的应用[J]. 电力系统保护与控制, 2010, 38(13): 74-78.
CHEN C L, XU T Y, ZHENG W, et al. Application of multi-class classification SVM in power quality disturbances classification[J]. Power System Protection and Control,



2010, 38(13): 74-78.

[15] 周高涵. 基于机器学习算法的电力系统暂态稳定性评估研究[D]. 武汉: 武汉理工大学, 2022.

ZHOU G H. Research on Power system transient stability assessment based on machine learning algorithms[D]. Wuhan: Wuhan University of Technology, 2022.

[作者简介]



廖银玲 (1986-), 女, 现就职于广西电网有限责任公司, 主要研究方向为安全管理、数字化应用等。



李金灿 (1976-), 女, 现就职于广西电网有限责任公司, 主要研究方向为电力用户用电安全、用电设施隐患排查及风险管控等。



王冰 (1972-), 女, 广西电网有限责任公司梧州供电局高级工程师, 主要研究方向为电力用户用电安全、用电设施隐患排查及风险管控等。



张君 (1988-), 女, 现就职于广西电网有限责任公司梧州供电局, 主要研究方向为用电检查、抄核收、市场交易等。



梁耀元 (1990-), 女, 现就职于广西电网有限责任公司梧州供电局长洲供电分局, 主要从事电力用户用电管理、电力用户安全隐患排查及整改、电力客户需求响应、电量抄核及电费回收等工作。