

基于图论及混合卷积神经网络的电力结算电量数据异常检测方法

张杰¹, 方浪森², 姚立明¹, 吴敬慧¹, 杨柳¹, 朱建全²

(1. 广东电力交易中心有限责任公司, 广州 510600; 2. 华南理工大学电力学院, 广州 510641)

摘要: 为提高电力市场结算的效率和准确性, 针对结算电量数据提出了一种基于图论及混合卷积神经网络的异常检测方法。首先, 使用混合重采样技术对输入数据进行预处理, 解决数据集的类别不平衡问题。其次, 基于图论将电量数据从一维序列结构转换为二维图结构, 并通过图卷积网络和卷积神经网络挖掘图结构的周期性规律和时间相关性特征, 提高对异常电量的检测精度, 并进一步在卷积神经网络中引入空间注意力机制以提高模型的检测性能。最后, 在实际电量数据集上进行异常数据检测, 结果表明所提方法在准确率和曲线下面积(area under curve, AUC)值等综合性能上具有优越性。

关键词: 电量数据; 异常数据检测; 卷积神经网络; 深度学习; 机器学习

Anomaly Detection Method for Power Settlement Electricity Data Based on Graph Theory and Hybrid Convolutional Neural Network

ZHANG Jie¹, FANG Langsen², YAO Liming¹, WU Jinghui¹, YANG Liu¹, ZHU Jianquan²

(1. Guangdong Electric Power Trading Center Co., Ltd., Guangzhou 510600, China; 2. School of Electric Power Engineering, South China University of Technology, Guangzhou 510641, China)

Abstract: In order to improve the efficiency and accuracy of electricity market settlement, an anomaly detection method is proposed for power settlement electricity data based on graph theory and hybrid convolutional neural network. Firstly, the input data is preprocessed using a hybrid resampling technique to solve the class imbalance problem in the data sets. Secondly, based on graph theory, the electricity data is transformed from a one-dimensional sequence structure to a two-dimensional graph structure, and the periodicity and temporal correlation characteristics of the graph structure are mined through graph convolutional network and convolutional neural network to improve the detection accuracy of abnormal electricity. Furthermore, a spatial attention mechanism is introduced into convolutional neural network to improve the detection performance of the model. Finally, abnormal data detection is performed on the actual power data sets. And the results show that the proposed method is superior in comprehensive performance such as accuracy and area under curve (AUC) value.

Key words: electricity data; anomaly data detection; convolutional neural network; deep learning; machine learning

0 引言

随着电力体制改革的不断推进, 越来越多省级电力市场试点正进入长周期结算试运行^[1-3]。作为

电力市场结算的基础, 电量数据由于市场主体众多、表计质量各异、数据传输丢包等原因而容易出现异常现象, 进而影响结算准确性^[4]。目前, 业务人员主要依靠经验对异常电量进行判断, 难以及时、高效地从海量电力结算数据中甄别出异常数据。因此, 亟需探索一种更为快速、准确的电量数据异常检测方法。

目前, 异常数据检测问题已得到一定研究, 现有方法主要分为基于系统状态的方法和基于机器学习

基金项目: 国家自然科学基金资助项目(51977081); 广东电力交易中心有限责任公司创新项目(GDKJXM20222721)。

Foundation item: Supported by the National Natural Science Foundation of China (51977081); the Innovation Project of Guangdong Electric Power Trading Center Co., Ltd. (GDKJXM20222721).

习的方法^[5]。其中,基于系统状态的方法主要利用电网物理模型推导出系统的状态变量,通过对比数据的一致性进行异常检测^[6]。文献[7]构建电力系统节点状态信任机制,通过比较相邻节点信任值是否低于阈值以检测节点中的虚假数据。文献[8]构建风电机组的风速-功率输出状态模型,结合风特征分类和实测数据拟合概率功率曲线以识别异常数据。然而,这类检测方法的性能依赖于系统的模型和参数,需要大量的参数和拓扑信息。此外,当系统结构发生改变时,检测方法性能将下降,适用性较差。而基于机器学习的方法从数据样本出发,通过训练模型挖掘样本数据中隐藏的规律,实现对电量数据的异常检测。文献[9]通过每一个用户的历史数据以及合成的错误数据集训练支持向量机(support vector machine, SVM)模型,以检测新样本的异常情况。文献[10]提出一种基于卷积神经网络(convolutional neural network, CNN)的检测方法,能有效识别分布式发电领域中的异常电量。此外,多层感知机(multi-layer perceptron, MLP)^[11]、反向传播(back propagation, BP)神经网络^[12]、决策树(decision tree, DT)^[13]等模型也常被用于数据异常检测。上述文献所提方法各有特点,但均采用单一模型,可能存在数据特征提取角度片面问题。因此,部分学者尝试从多模型融合的角度进行异常检测^[14-15]。文献[16]使用3种不同的机器学习(machine learning, ML)方法作为一级分类器,并利用时间卷积网络(temporal convolutional network, TCN)作为二级分类器整合这些机器学习算法的输出,从而构造一个一阶和二阶分类(first and second-order classification, FSC)模型以检测智能电网中的异常用电量,具有较好的准确性。文献[17]基于长短期记忆(long short-term memory, LSTM)网络和MLP构建混合深度神经网络,通过提取电量数据和辅助数据的特征以监测智能电表的异常。通过融合不同类型的单一模型可以从不同角度提取数据的特征,进而提高整体的异常数据检测性能。

然而,上述方法均基于一维电量数据构建异常检测模型,难以挖掘电量数据的周期规律性和时间相关性。为此,国内外学者针对数据升维技术展开相关研究。文献[18]采用格拉姆角场的方法将电能质量扰动(power quality disturbance, PQD)一维信号转化为二维图片,再采用图卷积网络(graph

convolutional network, GCN)对PQD图片进行训练和分类。然而,格拉姆角场使用极坐标变换和内积计算,反而增加了数据的复杂性和分析难度。文献[19]将一维电量数据按周排列成二维矩阵,并基于宽度和深度CNN模型检测异常电量数据。但是,CNN在提取二维输入数据特征过程中无法更加关注特征空间的重要区域。为此,文献[20]在CNN中引入空间注意力机制(spatial attention mechanism, SAM)以增大模型对部分重要特征空间的权重。将该方法应用于图像数据检测,显著提高了检测效果。

需要说明的是,机器学习模型的性能依赖于数据的分布和质量,对数据样本的类别是否平衡十分敏感^[21]。当正常样本数量远超异常样本时,样本的不平衡分布将导致机器学习模型向多数类倾斜,使其在检测过程中无法有效识别少数类异常样本^[22]。为解决该问题,文献[15]使用合成少数类过采样技术(synthetic minority oversampling technique, SMOTE)增加训练集中的少数类样本数量,并采用Stacking集成学习策略对异常数据进行检测。然而,SMOTE算法可能会引发过拟合问题,导致所提模型泛化能力下降。文献[23]采用随机欠采样技术和套索算法对训练集中的不平衡数据进行处理,并构建实值深度置信网络提取数据潜在特征。但是,欠采样会丢失潜在的有价值样本,导致模型产生欠拟合问题。文献[24]采用随机过采样与随机欠采样相结合的技术,在不同的采样比例下进行试验,最后选取检测效果最佳的比例进行应用。然而,随机采样方法通过对现有样本的随机复制或删除以构建平衡数据集,并未增加对训练分类器有效的数据信息。

综上所述,为提高异常电量的检测精度,本文提出一种基于图论及混合卷积神经网络的数据检测方法。与传统模型融合方法不同,本文基于图论将一维用电序列数据转换为二维图结构,以挖掘数据图结构的周期性规律和时间相关性特征,能显著提高检测精度。此外,本文提出了一种SMOTE过采样与实例硬度阈值(instance hardness threshold, IHT)欠采样结合的混合重采样技术,可有效提高检测模型对数据不平衡问题的适应性。最后,利用国家电网有限公司的实际数据进行测试,验证了所提方法的有效性。

1 数据综合预处理与图论转换

1.1 输入数据综合预处理

数据准备通常是进行异常检测的前提。针对海量电力数据集存在的数据缺失与类别不平衡问题,本文提出了一种数据综合预处理方法。首先,通过缺失值插补填充电力数据集中的缺失信息。接着,利用归一化技术保证不同特征的数值尺度一致。最后,使用混合重采样技术处理类别不平衡问题,提高输入数据的质量。

基于数据驱动的分类器对输入数据的完整性较为敏感。然而,由于传输过程中发生损坏以及硬件故障等原因,电力数据记录往往是不完整的,可能包含较多缺失的数据信息。在时间序列数据分析中,简单地忽略缺失值会显著影响模型的最终检测效果。为此,本文采用线性插值法填补缺失值,如式(1)所示:

$$f_1(x_i) = \begin{cases} x_i, x_i \notin \text{NaN} \\ \frac{x_{i-1} + x_{i+1}}{2}, x_i \in \text{NaN}, x_{i-1}, x_{i+1} \notin \text{NaN} \\ 0, x_i \in \text{NaN}, x_{i-1} \text{ 或 } x_{i+1} \in \text{NaN} \end{cases} \quad (1)$$

式中: $f_1(x_i)$ 为填补后的第 i 天的电量数据值; x_i 为第 i 天的用电量数据值; NaN 为空缺值集合。

除了数据缺失问题,电力数据集的不同样本之间数值相差较大,同样会影响机器学习模型的训练效果,导致模型误差增大。因此,使用式(2)所示的 Min-Max 方法进行数据归一化,使得各样本具有相同的数值尺度。

$$f_2(X_i) = \frac{X_i - \min(X)}{\max(X) - \min(X)} \quad (2)$$

式中: X_i 为样本 X 的第 i 个值; $\min(X)$ 为 X 中的最小值; $\max(X)$ 为 X 中的最大值; $f_2(X_i)$ 为 X_i 归一化后的数值。

针对数据集中类别不平衡问题, SMOTE-IHT 混合重采样在平衡整体数据方面具有显著优势。SMOTE 技术基于样本特征空间,通过线性插值的方法在少数类集合中生成新的数据实例。插值公式如式(3)所示^[25]。

$$X_{\text{new}}(i, j) = X_i + (X_j - X_i) \times \text{rand}(0, 1), j = 1, 2, \dots, k \quad (3)$$

式中: $X_{\text{new}}(i, j)$ 为合成样本; X_j 为 X_i 的 k 个近邻样

本中的第 j 个; $\text{rand}(0, 1)$ 为 0 至 1 之间的随机数。

通过 SMOTE 技术生成的新样本扩张了少数类样本的空间,导致与多数类样本的空间重合,容易造成模型的过拟合,利用 IHT 算法可以有效解决上述问题^[26]。IHT 算法的核心是实例硬度(instance hardness, IH),该指标常用来表征数据被错误分类的概率,其值用 I_h 表示。对于训练集 t 中的样本数据 (X_i, y_i) ,弱分类器 h 将其分类为 y_i 的条件概率为 $P(y_i|X_i, h)$ 。 $P(y_i|X_i, h)$ 的值越小,弱分类器 h 就越不准确,则该训练样本关于弱分类器 h 的 I_h 为:

$$I_h[(X_i, y_i)] = 1 - P(y_i|X_i, h) \quad (4)$$

设 H 为分类器 h 的集合,各权重为 $P(h|t)$,则训练数据 (X_i, y_i) 的实例硬度方程如式(5)所示。

$$\begin{aligned} I_h[(X_i, y_i)] &= \sum_H (1 - P(y_i|X_i, h)) P(h|t) \\ &= \sum_H P(h|t) - \sum_H P(y_i|X_i, h) P(h|t) \quad (5) \\ &= 1 - \sum_H P(y_i|X_i, h) P(h|t) \end{aligned}$$

然而,根据式(5)的定义,计算 IH 需要使用决策树、逻辑回归、随机森林等不同类别的模型进行多次训练,占用大量计算资源。因此,在实际应用中,可以通过 KDN (K-disagreeing neighbors, KDN) 值近似计算 I_h ,如式(6)所示^[27]。

$$K_{\text{DN}}(X_i) = \frac{|\{X_j: X_j \in K_{\text{NN}}(X_i) \wedge y_j \neq y_i\}|}{k} \quad (6)$$

式中: $K_{\text{DN}}(X_i)$ 为样本 X_i 的 k 个近邻样本中不同标签样本的比率; $K_{\text{NN}}(X_i)$ 为样本 X_i 的 k 个近邻样本集合。

IHT 算法根据实例硬度指标,在 SMOTE 生成的平衡数据中寻找 IH 较高的样本并将其剔除,使决策边界更加清晰,从而有效解决了 SMOTE 算法引起的过拟合问题。

1.2 基于图论的电量数据二维化方法

受社会生产和消费的影响,用户的用电数据存在明显的周期性规律和时间相关性^[28-29]。因此,本节基于图论的方法将一维的用户电量数据转换为二维的电量数据图结构,有助于更加全面地理解和分析数据的特征。

1.2.1 图论基础概念

图结构 G 可以用一个有序二元组 (V, E) 来表示。其中, V 为节点集合, $v_i \in V$ 表示节点 i , $\|V\| =$

n 表示节点数量; E 为边集合, e_{ij} 表示连接节点 i 和 j 的边。

图结构 $G=(V, E)$ 的特征信息可以用拉普拉斯矩阵的形式表示,其表达式为:

$$L = D - A \quad (7)$$

采用归一化的拉普拉斯方程表示为^[30]:

$$L^{\text{sys}} = I_N - D^{-1/2} A D^{-1/2} \quad (8)$$

式中: $A = (a_{ij})_{n \times n}$ 为图的邻接矩阵,若 $e_{ij} \in E$,则 $a_{ij} = 1$,否则, $a_{ij} = 0$; I_N 为 N 阶的单位矩阵; D 为图 G 的度矩阵,为一个对角阵,其对角线元素 $D_{ij} = \sum_{j=1}^n a_{ij}$ 。

1.2.2 电量数据二维化方法

以中国国家电网公司的某用户35天电量数据为例(相关数据见文献[19]),对电量数据二维化方法进行介绍,主要流程如图1所示。

首先,每天的电量数据可视为图的节点,则每个样本包括35个节点,每个节点中具有1个特征(即用电量数值);

其次,将电量时序数据按周进行切分,考虑到用电量的时间相关性,将每一个节点与其相邻的8个节点相连,例如节点1连接到节点2—9,节点2连接到节点1、节点3至节点9,以此类推;

最后,考虑到电力负荷曲线的周期性,将相邻周的同一天节点相连接,例如节点3与节点10相连接,节点4与节点11相连接,以此类推。

根据上述方法,可以将1维的电量数据转换为2维图结构,并获得图结构的特征矩阵 X 和邻接矩阵 A 。在特征提取时,为考虑节点自身的信息,需要对邻接矩阵 A 按照式(9)进行修正,从而给每个节点增加一条自连接。

$$A' = A + I_N \quad (9)$$




图1 电量数据转化为图结构的流程图

Fig. 1 Flowchart of converting electricity data into a graph structure

2 基于混合卷积神经网络的异常电量数据检测方法

为更好地利用二维电量数据图的周期性规律和时间相关性特征,本文提出基于混合卷积神经网络的异常电量数据检测模型,其结构如图2所示。

所提检测模型包括数据准备模块、GCN模块、CNN模块、混合模块和异常判断模块。其中,数据准备模块用以对原始不平衡数据进行混合重采样,并将1维用电时序数据转化为2维用电数据图,具体方法如第1节所述;GCN模块和CNN模块用于对用电数据图的特征矩阵和邻接矩阵进行卷积运算,提取用电数据的周期性规律和时间相关性特征;混合模块用于融合GCN模块和CNN模块的特征提取结果,并输出异常概率结果;异常判断模块用以判断并输出电量数据检测结果。下面将分别针对GCN模块、CNN模块和混合模块进行详细介绍。

2.1 GCN模块

GCN模块主要由输入层、图卷积层、池化层、全连接层和激活函数等组成^[31]。以图3所示的2个图卷积层和2个全连接层的GCN模型为例,说明在GCN模块中数据流的变化过程。

在第1个图卷积层中,对电量数据图结构的特征矩阵 X 和规范化后的邻接矩阵 A' 进行卷积计算,便可得到输出特征矩阵 H_1^G 。

$$H_1^G = \text{ReLU}(A' X W_1^G + b_1^G) \quad (10)$$

$$A'' = D^{-1/2} A' D^{-1/2} \quad (11)$$

式中 W_1^G 和 b_1^G 分别为第1个图卷积层的权重矩阵和偏置向量。

同理,经过第2个图卷积层后得到的输出数据为:

$$H_2^G = \text{ReLU}(A'' H_1^G W_2^G + b_2^G) \quad (12)$$




图2 基于混合卷积神经网络的异常电量数据检测模型结构图

Fig. 2 Schematic diagram of detection model for abnormal electricity data based on hybrid convolutional neural network




图3 GCN内部示意图

Fig. 3 Internal schematic diagram of GCN

式中： W_2^G 和 b_2^G 分别为第2个图卷积层的权重矩阵和偏置向量； H_2^G 为第2个图卷积层的输出向量。

在全连接层中，输出数据 H_3^G 可以通过权重矩阵 W_3^G 、偏置向量 b_3^G 和激活函数ReLU得到：

$$H_3^G = \text{ReLU}(H_2^G W_3^G + b_3^G) \quad (13)$$

同理，可以得到最后一层的输出结果为：

$$Y^G = \text{ReLU}(H_3^G W_4^G + b_4^G) \quad (14)$$

式中： W_4^G 和 b_4^G 分别为最后一层的权重矩阵和偏置向量； Y^G 为GCN模块的输出特征向量。

在上述数据处理过程中，特征矩阵 X 和规范化后的邻接矩阵 A'' 作为GCN模块的输入，包含了电量数据的周期性规律和时间相关性信息。经过多层图卷积层处理后，输出特征向量 Y^G 便可从中提取出这些电量数据的周期性规律和时间相关性特征。

2.2 CNN 模块

在CNN模块中，本文提出一种基于空间注意力机制的卷积神经网络模型。其中空间注意力机制的结构如图4所示。




图4 SAM的结构示意图

Fig. 4 Structure diagram of SAM

在空间注意力模块中，对输入特征 F 进行平均池化和最大池化处理得到特征向量 $F_{\text{avg}} = \text{AvgPool}(F)$ 和 $F_{\text{max}} = \text{MaxPool}(F)$ 。然后，通过卷积层和Sigmoid激活函数得到空间注意力输出权重 $M_s(F)$ ，再与输入特征 F 进行同位元素相乘，得到SAM的最终输出 F' ，具体公式为：

$$F' = M_s(F) \otimes F \quad (15)$$

$$\begin{aligned} M_s(F) &= \sigma(f([\text{AvgPool}(F); [\text{MaxPool}(F)]])) \\ &= \sigma(f([F_{\text{avg}}; F_{\text{max}}])) \end{aligned} \quad (16)$$

式中： $\sigma(\cdot)$ 为Sigmoid激活函数； $f(\cdot)$ 为卷积计算函数。

图5所示的基于空间注意力机制的卷积神经网络包含2个卷积层、1个空间注意力模块、1个池化层和1个全连接层。

在第1个卷积层中，输入数据为负荷特征矩阵 X ，输出数据为：

$$H_1^C = \text{ReLU}(XW_1^C + b_1^C) \quad (17)$$

式中 W_1^C 和 b_1^C 分别为权重矩阵和偏置向量。




图5 基于SAM的CNN结构示意图

Fig. 5 Structure diagram of CNN based on SAM

在空间注意力模块中, H_1^c 作为输入特征, 输出特征如下式所示:

$$H_2^c = M_s(H_1^c) \otimes H_1^c \quad (18)$$

与第1个卷积层相同, 经过第2个卷积层后得到的输出特征为:

$$H_3^c = \text{ReLU}(H_2^c W_3^c + b_3^c) \quad (19)$$

式中 W_3^c 和 b_3^c 分别为第2个卷积层的权重矩阵和偏置向量。

在池化层中采用最大池化可减少CNN的参数, 输出特征为:

$$H_4^c = \text{MaxPool}(H_3^c) \quad (20)$$

在CNN的最后一个全连接层中, 输出结果为:

$$Y^c = \text{ReLU}(H_4^c W_5^c + b_5^c) \quad (21)$$

式中: W_5^c 和 b_5^c 分别为全连接层的权重矩阵和偏置向量; Y^c 为CNN模块的输出特征向量。

从上述过程可见, CNN模块主要利用卷积核对特征矩阵 X 进行卷积计算, 以提取电量数据蕴含的潜在变化特征。

2.3 混合模块

图6展示了混合模块的内部结构。




图6 混合模块结构示意图

Fig. 6 Structure diagram of hybrid module

首先, 将GCN模块的输出特征向量 Y^G 和CNN模块的输出特征向量 Y^c 进行拼接, 得到 $[Y^G, Y^c]$ 。其次, 通过具有1个神经元的全连接层同时提取 Y^G

和 Y^c 所包含的电量数据时序特征。最后, 通过一个Sigmoid激活函数输出电量数据异常概率。

$$Y = \text{Sigmoid}([Y^G, Y^c] W_0 + b_0) \quad (22)$$

式中: Y 为混合模型的预测标签概率; W_0 为混合模型中全连接层的权重矩阵; b_0 为混合模型中全连接层的偏置向量。

在构建混合模型后, 考虑到电量数据异常检测是一个二元分类任务, 因此采用二元交叉熵作为损失函数, 通过梯度下降来更新权重。

$$\text{Loss} = -(Y_r \lg(Y) + (1 - Y_r) \lg(1 - Y)) \quad (23)$$

式中 Y_r 为真实的标签。

2.4 性能评估指标

为了对所提异常检测模型性能进行评估, 本文使用混淆矩阵(confusion matrix, CM)对检测结果进行统计。作为监督学习常用的可视化工具, CM以矩阵的形式将电量数据按照其真实标签与检测结果进行划分, 能够有效展示算法的性能。本文所研究的电量数据异常检测问题属于二分类任务, 其中0类标签表示正常数据, 1类标签则对应异常数据。在如表1所示的混淆矩阵中, TN(0, 0)和TP(1, 1)分别表示模型可以准确识别正常和异常数据, 而FP(0, 1)和FN(1, 0)则意味着电量数据检测错误。

表1 检测结果混淆矩阵

Tab. 1 CM of classification results

真实标签	检测结果	
	反例(0)	正例(1)
反例(0)	TN(真反例)	FP(假正例)
正例(1)	FN(假反例)	TP(真正例)

利用混淆矩阵可有效检验模型在准确率(其值用 A 表示)、精确度(其值用 P 表示)、召回率(其值用 R 表示)和 F_1 度量(其值用 F_1 表示)等不同指标上的性能, 具体如式(24)~(27)所示。

$$A = \frac{T_p + T_n}{T_p + T_n + F_p + F_n} \quad (24)$$

$$P = \frac{T_p}{T_p + F_p} \quad (25)$$

$$R = \frac{T_p}{T_p + F_n} \quad (26)$$

$$F_1 = 2 \times \frac{P \times R}{P + R} \quad (27)$$

式中: T_p 为被预测为正类的正样本数量; T_n 为被预

测为负类的负样本数量； F_p 为被预测为正类的负样本数量； F_N 为被预测为负类的正样本数量。

为保证所提方法在不同数据集上均能获得较好的效果，本文使用受试者工作特征(receiver operating characteristic, ROC)曲线下面积(area under curve, AUC)来衡量模型的泛化能力，其值用 A_{UC} 表示，计算公式如式(28)所示。

$$A_{UC} = \frac{\sum_{i \in P_c} R_{ank i} - \frac{M(1+M)}{2}}{M \times N} \quad (28)$$

式中： P_c 为正类样本； $R_{ank i}$ 为样本 i 按升序排列的秩值； M 和 N 分别为正样本和负样本的数量。

ROC曲线越接近左上角，说明模型的泛化性能越好(此时AUC的取值接近于1)。反之，如果ROC曲线贴近对角线或AUC值接近0.5，则表明模型几乎随机猜测样本类别，不具备检测能力。

2.5 所提异常检测方法流程

基于混合卷积神经网络的异常电量数据检测方法的具体流程如图7所示，主要分为以下3个阶段。

1)数据处理：对电量数据集进行缺失值填补和归一化预处理，然后按照本文所提方法进行重采样以及二维图转换；

2)模型训练：对训练集样本进行特征提取，并利用损失函数更新混合卷积神经网络模型的权重；

3)效果评估：对测试集样本进行异常电量数据检测，并通过准确率、 F_1 度量、ROC曲线等指标对所提模型的泛化性能进行评估。

3 仿真分析

为证明本文所提方法的有效性，采用来自中国国家电网有限公司42 372名居民用户从2014年1月1日至2016年10月31日总计1 034天的用电量数据^[19]进行仿真分析。其中，38 757名用户的用电数据正常，其余3 615名用户存在异常。

本文所提模型基于PyTorch深度学习框架，在Pycharm(基于Python3.10)中进行程序编写。实验平台的配置为NVIDIA GeForce RTX 3060 Laptop GPU及11th Gen Intel(R) Core(TM) i7-11800H @ 2.30 GHz CPU。

3.1 数据综合预处理

将数据集中的一维电量数据样本按照第1节所述方法进行综合预处理和图转换。首先，对数据集




图7 基于混合卷积神经网络的异常电量数据检测流程图

Fig. 7 Flowchart of abnormal electricity data detection based on hybrid convolutional neural network

进行缺失值填补、归一化处理。在原始电量数据集中，正常样本与异常样本的比例接近11:1。为了处理类别不平衡问题，本文使用第1.1节所述的SMOTE-IHT技术对数据进行混合重采样，获得数据质量较高的35 182个实验样本，其中正常电量数据样本和异常电量数据样本各占一半。接着，根据第1.2.2节所述图转换方法生成电量数据样本的二维图结构。最后，将样本集按照8:2的比例分为训练集和测试集进行实验。

3.2 模型参数设置

在本文所提的检测模型中，GCN模块包括2个图卷积层、1个最大池化层、1个扁平层和1个全连接层，激活函数均采用ReLU函数。其中，每个图卷积层的输出通道数为16，最大池化层大小为2，全连接层的神经元数量为32。在CNN模块中，主要包括2个卷积层、1个空间注意力模块、1个最大池化层、1个扁平层和1个全连接层，激活函数均采用ReLU函数。其中，第1个卷积层包含8个卷积核，第2个卷积层包含16个卷积核，各卷积核尺寸为2×2；最大池化层大小为2；空间注意力模块中的卷积核尺寸为7×7；全连接层神经元数量为32。

3.3 实验分析

3.3.1 电量数据时序特征分析

受社会生产生活规律的影响,用户的用电量会呈现一定的周期性规律和时间相关性,这为用电数据的异常检测提供了依据。以2014年1月1日—2014年1月28日的一个正常用电数据样本和一个异常用电数据数据样本为例进行分析,其用电曲线如图8所示。




图8 正常和异常用电数据曲线

Fig. 8 Normal and abnormal electricity consumption data curves

从图8(a)和(c)中可知,正常用户的周用电量曲线具有相似的形状,这表明该用户的用电量具有周期性变化规律。此外,该用户工作日的用电量比较相近(休息日的情况也类似),这表明该用户的用电量同时存在时间相关性。在图8(b)和(d)所示的异常用电数据则体现出不同的时序特征。比如,前2周的用电曲线呈现相似的特征。但是,该用户第3周的用电量从星期六开始突然下降,此后一直维持在较低水平。从这个角度看,用电量的是否具有周期性变化特征可作为异常检测的重要依据。

为更深入分析正常和异常电量数据的时序特征,分别计算其皮尔逊相关系数(Pearson correlation coefficient, PCC)矩阵^[19],结果如图9所示。

从图9可以看出,正常电量数据的PCC值均大于0.5,表明这些电量数据具有较强的相关性(PCC值越接近1,相关性越强,周期性变化规律越明显^[19]);而异常电量数据的PCC值较小,甚至出现




图9 正常和异常用电数据的PCC矩阵

Fig. 9 PCC matrixes for normal and abnormal electricity consumption data

负数,表明异常电量数据的相关性较弱,周期性变化规律不明显,甚至出现了反常的情况。

3.3.2 SMOTE-IHT混合重采样技术的有效性测试

对类别不平衡的数据集进行分类过程中,由于多数类占据样本中的主导地位,模型会向多数类倾斜,因此在识别少数类样本时会出现错误。为了证明混合采样处理不平衡类的有效性,以下设置2种算例进行对比分析,结果如表2—3所示。

算例1: 使用不平衡数据对所提方法性能进行测试;

算例2: 使用混合采样后的平衡数据对所提方法性能进行测试。

表2 不平衡数据检测结果混淆矩阵

Tab. 2 CM of classification results on imbalanced data

真实标签	检测结果/%	
	反例(0)	正例(1)
反例(0)	99.79	0.21
正例(1)	96.97	3.03

表3 平衡数据测试集检测结果混淆矩阵

Tab. 3 CM of classification results on balanced data

真实标签	检测结果/%	
	反例(0)	正例(1)
反例(0)	96.45	3.55
正例(1)	4.68	95.32

从表2和表3可知,在算例1中,检测模型可以识别出99.79%的正常样本。但是,对于异常样本,其检测准确率仅为3.03%。这是因为训练样本中绝大部分为正常样本,这种数据的不平衡会使训练后的检测模型的适应性向正常样本倾斜,从而造成其对少数异常样本的检测准确率偏低。相对而

言,在算例2中,由于采用SMOTE-IHT混合重采样对样本类别进行平衡处理,检测模型对正常样本和异常样本均保持较高的检测准确率(异常样本的检测准确率从3.03%提升到95.32%,而正常样本的检测准确率只有较小的下降)。这证明了SMOTE-IHT混合重采样技术可以较好地处理数据类别不平衡问题,提升模型检测精度。

3.3.3 不同检测模型的对比分析

为了更好地评估所提方法的性能,在同一数据集上选择SVM^[9]、DT^[13]、MLP^[11]、GCN、CNN模型和Adaboost^[32]、PFSC^[16]、GCN-CNN融合模型为典型代表进行对比实验,其中,CNN和GCN-CNN模型未引入空间注意力机制。表4描述了所提模型与对比模型的性能指标结果。为了更加直观地体现出模型效果,图10—11分别可视化展示各个模型的ROC曲线和AUC结果。

表4 各模型性能对比

Tab. 4 Performance comparison of each model

模型	Accuary	Precision	Recall	F1 Score
SVM	0.721	0.873	0.518	0.650
DT	0.606	0.556	0.962	0.705
MLP	0.803	0.793	0.813	0.803
GCN	0.682	0.662	0.744	0.701
CNN	0.732	0.713	0.742	0.727
Adaboost	0.838	0.814	0.871	0.841
PFSC	0.926	0.927	0.923	0.925
GCN-CNN	0.934	0.924	0.945	0.934
Proposed model	0.947	0.941	0.953	0.947




图10 各模型的ROC曲线

Fig. 10 ROC curves of each model




图11 各模型的AUC

Fig. 11 AUC of each model

由表4可知,SVM、MLP、GCN和CNN四种单一模型的准确率、精确度、召回率和 F_1 度量的结果均在0.60至0.82之间。此外,尽管DT的召回率很高(达到0.962),但是其精确度较低(仅有0.556),表明有较多的正常数据被误判为异常数据。相比之下,Adaboost、PFSC、GCN-CNN模型和所提混合模型在以上性能指标均达到0.9以上,具有显著提高,说明混合模型能够融合基础模型的优点,提高对异常数据的检测性能。进一步地,相比于GCN-CNN模型,在CNN中引入空间注意力机制后,所提模型在4个性能指标上分别提高了1.3%、1.7%、0.8%和1.3%,表现出更优的异常检测效果。这是因为空间注意力机制能够优化输入的权重,使模型更有效地关注输入数据中重要的区域,从而提高特征提取和异常检测的效果。

由图10可看出,相比于SVM、DT、MLP、GCN和CNN单一模型,混合模型的ROC曲线更贴近左上角。图11进一步比较了所提模型与对比模型的AUC结果,其中SVM、DT、MLP、GCN和CNN模型分别为0.721、0.605、0.874、0.745和0.764,说明单一模型对异常电量的检测效果较差。在所有混合模型中,所提模型的AUC结果最高(达到0.985),证明所提模型具有较好的检测性能。

3.3.4 所提方法对训练集大小的灵敏度分析

为分析所提方法对训练集大小的灵敏度,在不同训练集比例下对其进行了测试。在对比实验中,训练集比例 β 分别设定为50%、60%和70%,其他参数保持不变,结果如表5和图12所示。

表5 不同训练集比例下各模型的性能对比

Tab. 5 Performance comparison of models with different proportions of training sets

模型	P			R			A_{UC}		
	$\beta=50\%$	$\beta=60\%$	$\beta=70\%$	$\beta=50\%$	$\beta=60\%$	$\beta=70\%$	$\beta=50\%$	$\beta=60\%$	$\beta=70\%$
SVM	0.884	0.876	0.881	0.554	0.568	0.548	0.740	0.744	0.739
DT	0.562	0.560	0.561	0.961	0.962	0.962	0.606	0.607	0.607
MLP	0.692	0.733	0.744	0.651	0.730	0.848	0.736	0.808	0.853
GCN	0.699	0.758	0.73	0.731	0.606	0.654	0.775	0.775	0.772
CNN	0.709	0.719	0.703	0.732	0.716	0.747	0.756	0.748	0.760
Adaboost	0.826	0.822	0.819	0.864	0.862	0.863	0.913	0.911	0.908
PFSC	0.950	0.941	0.920	0.872	0.893	0.923	0.956	0.959	0.964
GCN-CNN	0.932	0.925	0.927	0.925	0.926	0.939	0.978	0.982	0.980
Proposed model	0.935	0.932	0.936	0.958	0.951	0.953	0.980	0.982	0.981




图12 不同训练集比例下各模型的Accuracy和F1 Score对比

Fig. 12 Comparison of accuracies and F1 scores of each model under different training set ratios

由表5和图12可知,在不同的训练集比例场景下, SVM、DT、MLP、GCN和CNN五种单一模型的各项性能指标波动较大。相比而言,所提模型的泛化性能较为稳定,其中AUC结果一直保持在0.98以上。这是因为,即使在相对较低的训练集比例下,二维图结构的特征矩阵和邻接矩阵也能为模型提供更多的样本特征。此外,相比于GCN-CNN模型,所提模型各项性能均有所提升,这说明引入空间注意力机制后,所提模型对特定空间位置的关注程度能够随训练集比例变化进行动态调整,从而更加灵活地捕捉输入数据中的关键信息。因此,本文所提模型对于训练集比例的要求更低,在保证稳定的检测性能情况下具有更好的鲁棒性。

4 结论

本文提出了一种基于图论的GCN和CNN混合

模型,用于识别电网中的异常电量数据,并在实际用电量数据集上进行测试,得到如下结论。

1) 本文采用SMOTE-IHT混合重采样技术处理电量数据的类别不平衡问题,有效提高了模型对少数异常样本的检测准确率,避免模型出现过拟合。

2) 本文所提的混合模型能够融合GCN和CNN两种模型提取用电数据图结构的周期性规律和时间相关性的优点,在异常数据检测问题上的准确率和AUC可分别达到94.7%和0.985,优于其他常规模型。此外,所提模型对于训练集规模的要求更低,具有更好的鲁棒性。

参考文献

- [1] 关立,常江,孙大雁,等.省间电力现货市场试运行分析及思考[J].电力系统自动化,2024,48(11):2-10.
GUAN Li, CHANG Jiang, SUN Dayan, et al. Analysis and reflection on trial operation of inter-provincial electricity spot markets in China[J]. Automation of Electric Power Systems,

- 2024, 48(11): 2 – 10.
- [2] 黄海涛, 顾颖, 叶云龙. 双轨制下新能源参与现货电能量市场的电力交易与结算方式[J]. 电力建设, 2024, 45(11): 174 – 188.
- HUANG Haitao, GU Ying, YE Yunlong. Electricity trading and settlement methods for renewable energy participation in the spot electricity market under the dual track system [J]. Electric Power Construction, 2024, 45(11): 174 – 188.
- [3] 李祥光, 谭青博, 李帆琪, 等. 电碳耦合对煤电机组现货市场结算电价影响分析模型[J]. 中国电力, 2024, 57(5): 113 – 125.
- LI Xiangguang, TAN Qingbo, LI Fanqi, et al. Analysis model to study the influence of electrocarbon coupling on settlement price of coal power units in spot market [J]. Electric Power, 2024, 57(5): 113 – 125.
- [4] 严明辉, 潘舒宸, 吴滇宁, 等. 基于非参数核密度估计的电力市场用户电量异常数据辨识与修正方法[J]. 现代电力, 2022, 39(1): 80 – 87.
- YAN Minghui, PAN Shuchen, WU Dianning, et al. An identification and correction method of abnormal data of electricity market consumers based on nonparametric kernel density estimation [J]. Modern Electric Power, 2022, 39(1): 80 – 87.
- [5] YAN Z, WEN H. Performance analysis of electricity theft detection for the smart grid: an overview [J]. IEEE Transactions on Instrumentation and Measurement, 2021 (71): 2502928.
- [6] LEITE J B, MANTOVANI J R S. Detecting and locating non-technical losses in modern distribution networks [J]. IEEE Transactions on Smart Grid, 2018, 9(2): 1023 – 1032.
- [7] XIE B, PENG C, YANG M, et al. A novel trust-based false data detection method for power systems under false data injection attacks [J]. Journal of the Franklin Institute, 2021, 358(1): 56 – 73.
- [8] 杨茂, 翟冠强, 苏欣. 基于风特征分析的风电机组异常数据识别算法[J]. 中国电机工程学报, 2017, 37(S1): 144 – 151.
- YANG Mao, ZHAI Guangiang, SU Xin. An algorithm for abnormal data identification of wind turbine based on wind characteristic analysis [J]. Proceedings of the CSEE, 2017, 37(S1): 144 – 151.
- [9] JOKAR P, ARIANPOO N, LEUNG V C M. Electricity theft detection in AMI using customers' consumption patterns [J]. IEEE Transactions on Smart Grid, 2016, 7(1): 216 – 226.
- [10] 薛阳, 杨艺宁, 廖文龙, 等. 基于非线性独立成分估计的分布式光伏窃电数据增强方法[J]. 电力系统自动化, 2022, 46(2): 171 – 179.
- XUE Yang, YANG Yining, LIAO Wenlong, et al. Data augmentation method for distributed photovoltaic electricity theft based on non-linear independent components estimation [J]. Automation of Electric Power Systems, 2022, 46(2): 171 – 179.
- [11] PEREIRA L A M, AFONSO L C S, PAPA J P. Multilayer perceptron neural networks training through charged system search and its Application for non-technical losses detection [C]//2013 IEEE PES Conference on Innovative Smart Grid Technologies (ISGT Latin America), April 15 – 17, 2013, Sao Paulo, Brazil. New York: IEEE, 2013.
- [12] 王庆宁, 张东辉, 孙香德. 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. Research and application of electricity anti-stealing system based on GA-BP neural network [J]. Electrical Measurement & Instrumentation, 2018, 55(11): 35 – 40.
- [13] 张爱梅. 基于不平衡电能数据的反窃电智能监测系统研究 [J]. 电工技术, 2024(4): 134 – 136.
- ZHANG Aimei. Imbalanced-electricity-data-based intelligent monitoring system against electricity theft [J]. Electric Engineering, 2024(4): 134 – 136.
- [14] 周赣, 华济民, 李铭钧, 等. 基于图转换和混合卷积神经网络的窃电检测方法[J]. 电力系统自动化, 2022, 46(19): 78 – 86.
- ZHOU Gan, HUA Jimin, LI Mingjun, et al. Electricity theft detection method based on graph transformation and hybrid convolutional neural network [J]. Automation of Electric Power Systems, 2022, 46(19): 78 – 86.
- [15] 游文霞, 李清清, 杨楠, 等. 基于多异学习器融合 Stacking 集成学习的窃电检测[J]. 电力系统自动化, 2022, 46(24): 178 – 186.
- YOU Wenxia, LI Qingqing, YANG Nan, et al. Electricity theft detection based on multiple different learner fusion by stacking ensemble learning [J]. Automation of Electric Power Systems, 2022, 46(24): 178 – 186.
- [16] KHAN I U, JAVEID N, TAYLOR C J, et al. A stacked machine and deep learning-based approach for analysing electricity theft in smart grids [J]. IEEE Transactions on Smart Grid, 2022, 13(2): 1633 – 1644.
- [17] BUZAU M M, TEJEDOR-AGUILERA J, CRUZ-ROMERO P, et al. Hybrid deep neural networks for detection of non-technical losses in electricity smart meters [J]. IEEE Transactions on Power Systems, 2020, 35(2): 1254 – 1263.
- [18] 黄光磊, 田启东, 林志贤, 等. 基于图卷积神经网络和格拉姆角场的电能质量扰动分类[J]. 电气传动, 2024, 54(3): 84 – 90.
- HUANG Guanglei, TIAN Qidong, LIN Zhixian, et al. Power quality disturbance classification based on graph convolutional neural networks and Gramian angular field [J]. Electric Drive, 2024, 54(3): 84 – 90.
- [19] ZHENG Z B, YANG Y T, NIU X D, et al. Wide and deep convolutional neural networks for electricity-theft detection to secure smart grids [J]. IEEE Transactions on Industrial Informatics, 2018, 14(4): 1606 – 1615.
- [20] 何国立, 齐冬莲, 闫云凤. 一种基于关键点检测和注意力机制的违规着装识别算法及其应用[J]. 中国电机工程学报, 2022, 42(5): 1826 – 1837.
- HE Guoli, QI Donglian, YAN Yunfeng. An illegal dress recognition algorithm based on key-point detection and attention mechanism and its application [J]. Proceedings of the CSEE, 2022, 42(5): 1826 – 1837.
- [21] 王怀远, 陈启凡. 基于代价敏感堆叠变分自动编码器的暂态稳定评估方法[J]. 中国电机工程学报, 2020, 40(7): 2213 – 2220, 2400.
- WANG Huaiyuan, CHEN Qifan. A transient stability assessment method based on cost-sensitive stacked variational auto-encoder [J]. Proceedings of the CSEE, 2020, 40(7): 2213 – 2220, 2400.
- [22] 孙喆. 基于机器学习的电力用户窃电行为检测[D]. 北京: 华北电力大学, 2023.
- [23] 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 Xianrong, 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.
- [24] FIGUEROA G, CHEN Y S, AVILA N, et al. Improved practices in machine learning algorithms for NTL detection with imbalanced data[C]//2017 IEEE Power & Energy Society General Meeting, July 16 – 20, 2017, Chicago, IL, USA. New York:IEEE, 2017.
- [25] 张梦, 陈旭勇, 彭元林, 等. 基于改进合成少数类过采样技术的非概率可靠性指标解[J]. 武汉工程大学学报, 2024, 46(2): 231 – 236.
- ZHANG Meng, CHEN Xuyong, PENG Yuanlin, et al. Solution to non-probabilistic reliability indices based on improved synthetic minority oversampling technique [J]. Journal of Wuhan Institute of Technology, 2024, 46(2): 231 – 236.
- [26] 罗超月岭, 郑韵馨, 徐帧雨, 等. 基于 Borderline-SMOTE-IHT 混合采样的改进 GWO-SVM 变压器故障诊断方法[J]. 智慧电力, 2023, 51(7): 108 – 114.
- LUO Chaoyueling, ZHENG Yunxin, XU Zhenyu, et al. Improved GWO-SVM transformer fault diagnosis method based on Borderline-SMOTE-IHT mixed sampling [J]. Smart Power, 2023, 51(7): 108 – 114.
- [27] SMITH M R, MARTINEZ T, GIRAUD-CARRIER C. An instance level analysis of data complexity [J]. Machine learning, 2014(95): 225 – 256.
- [28] 辛媛. 面向海量数据的电力负荷可视化与分析预测方法研究[D]. 南京: 东南大学, 2022.
- [29] 白云霄, 许遵楠, 季天瑶, 等. 北欧电力衍生品市场对中国电力中长期市场建设的启示[J]. 南方电网技术, 2025, 19(8): 70 – 80.
- BAI Yunxiao, XU Zunnan, JI Tianyao, et al. Inspiration of the nordic electricity derivatives market for the construction of China's medium and long-term electricity market[J]. Southern Power System Technology, 2025, 19(8): 70 – 80.
- [30] 刘菡, 王英男, 李新利, 等. 基于互信息-图卷积神经网络的燃煤电站 NO_x 排放预测[J]. 中国电机工程学报, 2022, 42(3): 1052 – 1060.
- LIU Han, WANG Yingnan, LI Xinli, et al. Prediction of NO_x emissions of coal-fired power plants based on mutual information-graph convolutional neural network [J]. Proceedings of the CSEE, 2022, 42(3): 1052 – 1060.
- [31] 廖文龙, 于赞, 王煜森, 等. 基于图卷积网络的配电网无功优化[J]. 电网技术, 2021, 45(6): 2150 – 2160.
- LIAO Wenlong, YU Yun, WANG Yusen, et al. Reactive power optimization of distribution network based on graph convolutional network [J]. Power System Technology, 2021, 45(6): 2150 – 2160.
- [32] 游文霞, 申坤, 杨楠, 等. 基于 AdaBoost 集成学习的窃电检测研究[J]. 电力系统保护与控制, 2020, 48(19): 151 – 159.
- YOU Wenxia, SHEN Kun, YANG Nan, et al. Research on electricity theft detection based on AdaBoost ensemble learning [J]. Power System Protection and Control, 2020, 48(19): 151 – 159.

收稿日期: 2024-03-01; 网络首发日期: 2024-10-23

作者简介:

张杰(1988), 男, 高级工程师, 硕士, 研究方向为电力市场、电力营销, 263381720@qq.com;

方浪森(1997), 男, 硕士研究生, 研究方向为电力市场、人工智能在电力系统的应用, fanglangsen@126.com;

朱建全(1982), 男, 通信作者, 教授, 博士, 研究方向为电力系统优化运行、电力市场, zhujianguan@scut.edu.cn。

征稿启事

《南方电网技术》是由中国南方电网有限责任公司主管、南方电网科学研究院有限责任公司主办的电力技术类科技期刊,向国内外公开发行人。刊登电力系统的科研、规划、设计、工程、生产运行、设备和系统维护等方面的成果、经验和动态,尤其是科研创新方面的论文。设有特约专稿、高压直流输电、高电压与绝缘、系统分析与运行、控制与保护、调度与通信、输变电技术、电力技术经济、智能电网、分布式电源与微电网、低碳电力等栏目。热烈欢迎国内外的电力研究人员、工程技术人员、大专院校师生踊跃投稿。

1 文稿要求

1)文稿应未在其他刊物上发表过,译文稿件须附上原作者的书面许可证明。内容要有科学性、创新性和实用性;论点明确、数据可靠、说理严谨、数学推导简明;语言流畅、文字简练、层次分明、重点突出。

2)学术论文请按GB/T 7713.2—2022《科学技术报告、学位论文和学术论文的编写格式》书写,篇幅以版面不超过9 000字(包括图表所占篇幅)为宜。同时请写明如下a、b、c、d、e五项:

a)作者署名(不宜超过7位)、作者单位、地址、电话、email信箱和邮政编码;

b)论文题目和作者单位英译文,作者姓名的汉语拼音;

c)作者的简历,包括姓名、出生年、性别、籍贯、职称、学位、当前从事的研究或工作等项;

d)350字左右的中文摘要,3~8个关键词,以及摘要和关键词相应的英文文本。摘要采用第三人称写法,内容包括论文的目的、方法、结果和结论;

e)若为国家基金资助项目或部、省级重大科研攻关项目,请提供项目名称及编号。

2 书写格式

1)要求文稿正文字号为5号,汉字字体为宋体,英数字体为Times New Roman,希腊字体为Symbol。文稿须采用可编辑的电子文档形式。

2)计量单位采用国家法定计量单位和符号,不能用“大气压”、“kgf/cm²”、“卡”、“ppm”等已废除的计量单位。

3)文中和公式中容易混淆的字符请注明文种(希文、英文、罗马字等)、大小写、上下标及上下标字母含义,表示矢量及矩阵的字符用黑斜体表示或特别注明。

4)文稿标题中不宜用缩略词(化学符号和公知公用者除外);摘要和正文中的缩略词在第一次出现时必须写出全称,后加括号附缩略词。

3 表格、插图及参考文献

1)表格尽量采用“三线表”。表格的上方写表序和表名。表名应有自明性且中文、英文表名并列。表注放在表底,缩入1个汉字以“注:”起头排版。

2)插图的下放应有图序和图名。图名应有自明性且中英文图名并列。工程图、电气图和函数图采用AutoCAD、

Adobe Illustrator或Corel DRAW软件绘制,工程图和电气图要符合国家标准规定,函数图要标明曲线序号及其注释,坐标轴上要有标值、标目,注明物理量和单位;数码照片图具备200万总像素以上。

3)图片和表格中的文字、变量、单位和数字要齐全、清晰。

4)参考文献应选用公开发表的资料,按引用的先后次序列表于文后,以[1]、[2]…标识序号,且与正文中的指示序号一致。按《信息与文献 参考文献著录规则,GB/T 7714—2015》和《中国学术期刊(光盘版)检索与评价数据规范,CAJ-CD B/T 1—2006 修订版试行稿》的要求著录文后参考文献。中文参考文献后要并列其英文译文(如示例[6]所示)。

文献类型及其标识为:普通图书[M];会议论文[C];报纸文章[N];期刊文章[J];学位论文[D];报告[R];标准[S];专利[P];汇编[G];档案[B];古籍[O];参考工具[K];其他未说明的文献类型,例如可公开的政府行政部门编号文件、行业或大公司的技术规范或工作手册[Z]。网上期刊[J/OL];网上电子公告[EB/OL]。电子文献尚需在载体标记后加上发表或更新日期(加圆括号)、引用日期(加方括号)和电子文献网址。

4 投稿

1)请登录《南方电网技术》编辑部网站<https://nfdwjs.csg.cn>,选择“作者登录”,登录或注册登录后选择投稿并按提示操作,登录方面出现问题请致电020-36625646咨询。

2)投稿时务必附上联系电话(手机为佳)。

3)编辑部不保证留存稿件,请作者自留底稿。稿件评审进程和结论可在《南方电网技术》编辑部网站上即时查询。作者也可致电020-36625642、36625643或发送电子邮件到nfdwjs@csg.cn向编辑部了解审稿情况。

4)文章一经发表,编辑部便取得作者的自动授权,可将文章收录入本刊网站,及与本刊有合作关系的数据库。

参考文献著录格式示例:

- [1] 刘国钧,陈绍业,王凤翥.图书馆目录[M].北京:高等教育出版社,1957:15-18.
- [2] 钟文发.非线性规划在可燃毒物配置中的应用[C]//赵玮.运筹学的理论与应用——中国运筹学会第五届大会论文集.西安:西安电子科技大学出版社,1996:468-471.
- [3] 冯西桥.核反应堆压力管道与压力容器的LBB分析[R].北京:清华大学核能技术设计研究院,1997.
- [4] 中国国家标准化管理委员会.信息与文献 参考文献著录规则:GB/T 7714—2015[S].北京:中国标准出版社,2015.
- [5] 邓一刚.全智能节电器:200610171314.3[P].2006-12-13.
- [6] 陈祥.无线技术在现代电网管理中的应用与展望[J].南方电网技术,2009,3(6):85-89.
CHEN Xiang. Development of wireless technology in modern power grid management and its perspective [J]. Southern Power System Technology, 2009, 3(6): 85-89.
- [7] 王明亮.关于中国学术期刊标准化数据库系统工程的进展[EB/OL].(1998-08-16)[1998-10-04].<http://www.cajcd.edu.cn/pub/wml.txt/980810-2.html>.

《南方电网技术》编辑部