

DOI: 10.19783/j.cnki.pspc.220074

# 基于 SE-CNN 模型的窃电检测方法研究

夏睿, 高云鹏, 朱彦卿, 欧阳博, 吴聪

(湖南大学电气与信息工程学院, 湖南 长沙 410082)

**摘要:** 针对传统电网现有窃电检测仅用单一电量且实际数据集下检测准确度低的问题, 提出一种基于通道注意力网络改进卷积神经网络模型的窃电行为检测方法。首先建立一种包含用电量趋势、线损增长率、终端告警多源数据融合的窃电评价指标体系, 以此构建用户用电特征集。然后, 基于通道注意力挤压激励网络(squeeze and excitation networks, SENet)优化卷积神经网络(convolutional neural network, CNN)模型, 据此构建自适应通道注意力网络改进卷积神经网络模型的窃电检测方法。最后, 利用南方电网数据集对提出方法的有效性进行验证。实测结果表明, 所提方法能有效实现实际电网情况下各类窃电行为准确检测, 建立的评价指标体系可更明显表征窃电行为规律。构建的窃电检测模型可自适应对特征通道重要程度调整, 提升通道利用率。相比现有检测方法, 其具有更高准确度和更优泛化性能。

**关键词:** 窃电行为; 改进卷积神经网络; 注意力网络; 电量趋势; 线损

## A detection method of electricity theft behavior based on an SE-CNN model

XIA Rui, GAO Yunpeng, ZHU Yanqing, OUYANG Bo, WU Cong

(College of Electrical and Information Engineering, Hunan University, Changsha 410082, China)

**Abstract:** There is a problem that the existing electricity theft detection of traditional power grids only uses a single amount of electricity and the detection accuracy is low under the actual dataset. Thus a method of electricity theft behavior detection based on a channel attention network improved convolutional neural network model is proposed. First, a multi-source data fusion electricity theft evaluation index system is established. This includes the trend of electricity consumption, the growth rate of line loss, and the terminal alarm, so as to construct the user's electricity consumption feature set. Then, the convolutional neural network (CNN) model is optimized based on the channel attention squeeze and excitation networks (SENet). Thus an electricity theft detection method based on an improved CNN model of the adaptive channel attention network is constructed. Finally, the dataset of the China Southern Power Grid is used to verify the validity and accuracy of the proposed method. Actual measurement results show that the proposed method can effectively realize the accurate detection of various electricity theft behaviors in the actual power grid situation, and the established evaluation index system can more clearly characterize the electricity theft behavior rules. The constructed electricity theft detection model can adaptively adjust the importance of feature channels to improve channel utilization. Compared with existing detection methods, it has higher accuracy and better generalization ability.

This work is supported by the National Natural Science Foundation of China (No. 51777061).

**Key words:** electricity theft behavior; improved convolutional neural network; attention network; electricity consumption trend; line loss

## 0 引言

电力传输过程中电力损失不可避免, 用户侧的

窃电行为是当前造成非技术性损失的主要原因<sup>[1-2]</sup>。每年因窃电造成的经济损失不仅在发展中国家影响巨大, 在发达国家同样严重<sup>[3]</sup>, 对电力公司来说, 会增加电网的运营成本, 同时给电网安全运行带来巨大的潜在风险<sup>[4-6]</sup>。因此, 研究如何对窃电用户准确检测, 降低非技术损失, 对于电力公司具有重大意义。

**基金项目:** 国家自然科学基金项目资助(51777061); 广西电网科技项目资助(GXKJXM20200020)

针对窃电检测技术, 近些年国内外诸多学者做了大量的工作。传统窃电检测主要利用人工对可疑用户进行稽查, 但该方法效率低且人力和时间成本高。随着智能电网的高速发展, 基于能源互联网的高级量测体系(Advanced Metering Infrastructure, AMI)在电网公司逐步建立, 同时伴随智能电表大面积应用, 可有效利用 AMI 下的智能电表数据对窃电行为展开研究分析<sup>[7]</sup>。机器学习因具有从大量历史数据中挖掘其隐含的规律并对新数据预测或判断的能力, 已开始被应用于窃电检测领域<sup>[8]</sup>, 其中无监督学习可通过学习用户用电数据内在相似关联属性, 自动提取用户用电典型特征聚类正常用户, 找出离群点作为异常用户<sup>[9-10]</sup>。文献[11]提出基于集群点算法的窃电检测模型, 但由于无特征提取阶段, 且算法简单, 造成检测准确度低。为解决以上问题, 文献[12]提出基于时间尺度负荷序列的特征提取, 并采用基于网格的局部离群因子算法对窃电行为进行检测, 然而特征提取过程复杂且计算量大。文献[13]提出生成对抗网络生成逼真窃电样本, 增强窃电样本多样性, 简化建模过程, 但无监督学习方法对参数严重依赖, 不适用于复杂电网环境和多种类窃电手段检测<sup>[14]</sup>。

为克服无监督学习方法对窃电检测的不足, 可采用基于有监督学习方法检测, 该类方法需含有标签的数据集进行训练, 将训练好的模型对新用电数据进行分类(即是否为窃电)<sup>[15]</sup>。文献[16-17]分别采用 SVM 和决策树方法进行窃电行为检测, 为进一步提高检测准确度, 将 AdaBoost 和 XGboost 等集成学习方法应用于窃电检测领域<sup>[18-21]</sup>, 但上述方法未对数据进行特征提取, 无法找出用电数据时间序列特征, 为此可采用神经网络<sup>[22-23]</sup>和 LSTM<sup>[24-25]</sup>进行特征提取。卷积神经网络是当下应用非常广泛而且有效的深度学习方法, 其广泛应用于图像处理、语音识别以及自然语言处理等领域, 在窃电领域应用具有较高的准确率<sup>[26]</sup>。文献[27]提出将 CNN 和随机森林结合的新型混合模型对窃电进行检测, 但采用篡改公式对正常数据集模拟窃电行为无法完全应用于真实复杂电网环境。文献[28]提出一种将宽度和深度结合的卷积神经网络, 采用国家电网数据集对窃电行为检测, 然而该数据集仅包含不同用户日用电量的单一信息, 其表征出的窃电行为所具有的特征不明显, 且模型训练前未对数据进行变换。目前大部分 CNN 模型均为空间维度通过增加网络深度提升网络性能<sup>[29-31]</sup>, 但因其网络层数增加, 通道增多而造成模型训练时间增加, 模型检测效率低。

因此, 本文针对实际电网情况下跨类杂糅用户

窃电行为的准确检测, 建立一种包含用电量趋势、线损增长率、终端告警多源数据融合的窃电评价指标体系, 以此建立用户用电特征指标, 构建用户用电特征集, 基于 CNN 模型引入通道注意力网络 SENet 对特征通道的重要程度进行调整, 提升通道利用率, 据此建立基于通道注意力网络 SENet 的 CNN 模型的窃电检测方法, 并在此基础上进行模型训练和测试, 最后通过南方电网某地区实际用户用电数据集对本文提出方法的准确性和有效性进行分析与验证。

## 1 窃电评价指标构建

在 AMI 体系下, 通过智能电表采集电量、负荷在一定程度上能反映用户窃电行为的某些规律, 但需建立更符合电网实际情况的窃电检测模型, 有必要构建新的具有更明显特征的评估指标体系, 以此建立用户用电特征指标, 获得用户用电特征集。构建的新评价指标体系如图 1 所示。

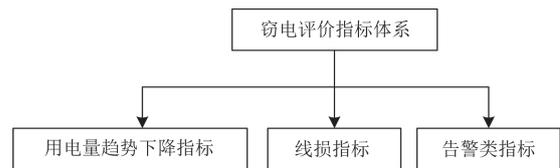


图 1 窃电评价指标体系

Fig. 1 Electricity theft evaluation index system

### 1.1 用电量趋势下降指标

一般情况下, 正常用户用电量趋势较为平稳, 而窃电用户用电量从特定时刻开始出现明显的持续下降趋势<sup>[32]</sup>。因此, 可统计设定当天前后  $h$  天为统计窗口期, 考虑该时段内的下降趋势, 并使用通过电力的线性曲线拟合获得的斜率作为度量。若斜率随着时间持续下降, 则用户成为窃电用户的可能性增加。计算该  $2h+1$  天内的用电量趋势下降情况, 其中第  $i$  天用电量趋势为考虑前后  $h$  天的用电量斜率, 即

$$k_i = \frac{\sum_{l=i-h}^{i+h} (f_l - \bar{f})(l - \bar{l})^2}{\sum_{l=i-h}^{i+h} (l - \bar{l})^2} \quad (1)$$

式中:  $k_i$  表示第  $i$  天的电量趋势;  $\bar{f} = \frac{1}{2h+1} \sum_{l=i-h}^{i+h} f_l$ ;

$\bar{l} = \frac{1}{2h+1} \sum_{l=i-h}^{i+h} l$ ;  $f_l$  为第  $l$  天的用电量。

若用户用电量趋势不断下降, 而认定该用户具有一定窃电嫌疑, 则计算该  $2h+1$  天内, 当天比前

一天用电量趋势为递减的天数,则有

$$D(i) = \begin{cases} 1, & k_i < k_{i-1} \\ 0, & k_i \geq k_{i-1} \end{cases} \quad (2)$$

式中:  $D(i)$  为判断第  $i$  天与第  $i-1$  天相比用电量趋势值是否递减的函数;  $k_{i-1}$  为第  $i-1$  天用电量趋势值。而该  $2h+1$  天内的电量趋势下降指标为

$$T = \sum_{n=i-(h-1)}^{i+h} D(n) \quad (3)$$

## 1.2 线损指标

在实际工程应用中,因企业任务波动、天气变化对办公用电的影响等,仅依靠用电量趋势下降指标容易造成误判,因此考虑增加线路的线损率作为用户线损率的参考值。线损率主要用于衡量供电线路损失的比例,为计算用户所属线路当天的线损率,本文结合线户拓扑关系图(如图 2 所示)进行计算,该条线路上同时供给多个用户,若第 1 天的线路供电量为  $s_l$ ,线路上各用户总用电量为  $\sum_m f_l^{(m)}$ ,则该线路线损率  $t_l$  计算式为

$$t_l = \frac{s_l - \sum_m f_l^{(m)}}{s_l} \times 100\% \quad (4)$$

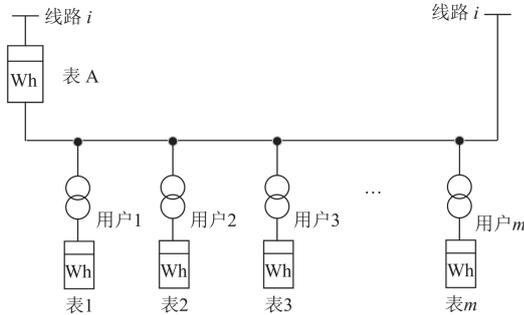


图 2 供电线路与用户的拓扑关系图

Fig. 2 Topological diagram of supply lines and users

针对统计当天设定前后  $h$  天为统计窗口期,首先分别计算统计当天与前  $h$  天之间的线损率平均值  $V_i^1$ ,当天与后  $h$  天之间的线损率平均值  $V_i^2$ ,若  $V_i^1$  比  $V_i^2$  的增长率大于 1%,则认为具有一定窃电嫌疑,定义线损率指标为

$$E(i) = \begin{cases} 1, & \frac{V_i^1 - V_i^2}{V_i^2} > 1\% \\ 0, & \frac{V_i^1 - V_i^2}{V_i^2} \leq 1\% \end{cases} \quad (5)$$

## 1.3 告警类指标

为尽可能全面覆盖各类疑似窃电方式,建模样

本数据还需考虑在 AMI 体系下,计量自动化系统出现的与疑似窃电行为相关的终端报警,其指标如表 1 所示,主要包括:“1”代表电压缺相、“2”代表电压断相、“3”代表电流反极性、“4”代表电流不平衡、“5”代表最大需量复零,综上以计算发生与疑似窃电相关的终端报警次数总和作为告警类指标。

表 1 终端告警类指标

Table 1 Terminal alarm indicators	
终端报警序号	相关终端报警内容
1	电压缺相
2	电压断相
3	电流反极性
4	电流不平衡
5	最大需量复零

## 2 基于 SE-CNN 窃电行为检测算法

### 2.1 卷积神经网络

为提取用户用电数据时间序列特征,实现窃电用户的准确识别,本文采用卷积神经网络进行窃电行为检测。典型卷积神经网络由输入层、卷积层(convolutional layer)、池化层(pooling layer)、全连接层(fully connected layer, FC)及输出层组成<sup>[33]</sup>,其模型框架如图 3 所示。

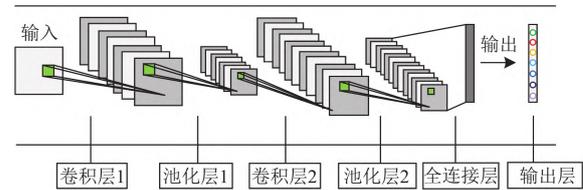


图 3 卷积神经网络模型框架

Fig. 3 Architecture of the CNN model

卷积层为 CNN 的核心组成模块,由一组平行特征图(Feature Map)组成,通过卷积核(convolution kernel)对输入特征图进行卷积运算得到输出特征图,该特征图中所有元素均通过同一个卷积核计算,即权值和偏置项共享。卷积运算为

$$\mathbf{x}_j^r = \mathbf{f} \left( \sum \mathbf{x}_i^{r-1} \times \mathbf{k}_{i,j}^r + \mathbf{b}_j^r \right) \quad (6)$$

式中:  $\mathbf{x}_j^r$  为通过第  $r$  层卷积运算所得的第  $j$  个输出特征图;  $\mathbf{b}_j^r$  表示第  $r$  层网络第  $j$  个卷积核的偏置;  $\mathbf{k}_{i,j}^r$  表示与第  $i$  个输入特征图运算的第  $j$  个卷积核;  $\mathbf{f}$  为非线性激活函数(一般选用 ReLU 函数),以提高网络的拟合能力与稀疏性。

池化层用于 CNN 降低特征图的特征空间,减少冗余特征量,同时保留用电行为主要特征,通过减少计算参量以达到降维效果,防止过拟合现象,从而提高模型泛化能力。实际上池化操作是一种下

采样操作，其操作包括最大池化、均值池化、随机池化等。CNN 中最典型的池化操作为最大池化<sup>[33]</sup>，为保证用电特征的主要特征、降低参数量，本文采用最大池化进行计算，其将输入特征划分为若干矩形区域，对每个子区域输出最大值，其输出计算式为

$$y_{k,i,j} = \max_{(m,n) \in R_{i,j}} x_{k,m,n} \quad (7)$$

式中： $y_{k,i,j}$  代表与第  $k$  个特征图相关的在矩形区域  $R_{i,j}$  的最大池化输出值； $x_{k,m,n}$  表示矩形区域  $R_{i,j}$  中位于  $(m,n)$  处的元素。

全连接层将 CNN 中最后一个池化层的所有神经元进行全连接操作，其模型可表示为

$$O(x) = f(wx + b) \quad (8)$$

式中： $x$  为全连接层的输入； $w$  为权值矩阵； $b$  为偏置向量。

### 2.2 自适应注意力机制

在采用 CNN 网络对窃电行为进行检测时，存在无用信息被 CNN 网络提取，而这些无用信息也会分布在特征图的通道维度里，分散 CNN 网络的“注意力”，严重影响窃电检测的准确度。据此本文采用通道维度的自适应注意力模块 SENet 模型对 CNN 获得特征表达进行有效融合，提高 CNN 模型的检测性能，其结构如图 4 所示。

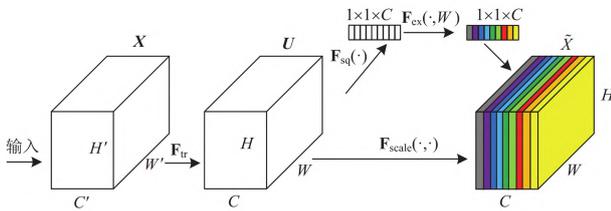


图 4 SENet 模型

Fig. 4 SENet model

注意力机制的本质在于模仿人类视觉注意力机制，忽略掉上下文不相关的信息，其被广泛应用于自然语言处理领域。神经网络中注意力机制常用于通道维度里，从大量的输入信息里筛选重要信息再给这些信息分配不同的权值。如图 4 所示，SE 模块 (SENet 简称) 主要包括挤压 (Squeeze) 以及激励 (Excitation) 两个操作，可适用于任何映射  $F_{tr}: X \rightarrow U$ ，输入为  $X \in \mathbb{R}^{H' \times W' \times C'}$ ，输出  $U \in \mathbb{R}^{H \times W \times C}$ 。SENet 提出挤压操作，即图 4 中  $F_{sq}(\cdot)$ ，将一个通道上整个空间特征编码为一个全局特征，其计算式为

$$Z_c = F_{sq}(U_c) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W U_c(i,j) \quad (9)$$

式中： $Z_c$  代表挤压操作生成的权重； $c \in (1, C)$ ， $C$  为特征图通道数； $W$ 、 $H$  代表特征图尺寸； $U_c(i,j)$

为输入特征第  $c$  通道中第  $i$  行第  $j$  列的值。挤压操作得到全局描述特征，通过另一种运算来抓取通道之间的关系。

激励操作的目的是获取特征通道之间的相关性，其需满足两个准则：第一是可学习到各通道间的非线性关系；第二点是学习的关系不是互斥的，因其允许多通道特征，而非 one-hot 形式。据此本文采用 sigmoid 形式的门控机制得到归一化后的权重向量  $S$  如式(10)所示。

$$S = F_{ex}(Z, W) = \sigma(g(Z, W)) = \sigma(W_2 \delta(W_1 Z)) \quad (10)$$

式中： $W_1 \in \mathbb{R}^{(C/r) \times C}$ ； $W_2 \in \mathbb{R}^{C \times (C/r)}$ ； $\delta$  和  $\sigma$  分别代表激活函数 ReLU 和 sigmoid。为降低模型复杂度及提升泛化能力，采用包含两个全连接层的 bottleneck 结构，其中第一个 FC 层起到降维作用，降维系数  $r$  是个超参数，表示中间层的隐层节点数；再采用 ReLU 函数激活并采用 FC 层恢复原始的维度；最后将学习到的各个通道的权值乘以  $U$  上的原始特征，其输出 SENet 结果为

$$\tilde{X} = F_{scale}(U_c, S_c) = S_c \otimes U_c \quad (11)$$

式中： $\tilde{X} = [\tilde{x}_1, \tilde{x}_2, \dots, \tilde{x}_c]$ ； $U_c$  代表通过计算每个通道上的特征图； $S_c$  代表通道权值； $\otimes$  代表逐元素相乘。上述整个操作可看成学习到各通道的权重系数，从而使得模型对各通道的特征更有辨别能力，由此构成一种自适应的注意力机制。

### 2.3 SE-CNN 窃电行为检测

为实现窃电行为的准确检测，本文使用 CNN 提取时间序列的关联特征，并引入了自适应注意力机制 SENet 模块，构建一种新型的 SE-CNN 窃电行为检测模型，其模型框架如图 5 所示。该模型主要由 2 个卷积层(卷积核为  $3 \times 3$ )、2 个池化层(其中 pool 1 的网络为  $3 \times 3$ ，pool 2 的网络为  $2 \times 2$ )、1 层 SENet 模块、2 个全连接层以及 1 个 sigmoid 函数  $\sigma(\cdot)$  的分类器构成。SE-CNN 模型训练的具体参数如表 2 所示。

SE-CNN 窃电行为检测模型实验流程如图 6 所示，首先对 AMI 体系下智能电表采集的南方电网原始用户用电数据进行预处理，其中包括缺失值的补值和离群值修复，另结合实际情况，居民节假日用电量与工作日相比明显偏低，为尽可能达到较好的数据效果，过滤节假日用电数据；再提取在图 1 构建的窃电评价指标 3 类特征；在模型训练和分类阶段，利用上述提取的特征作为数据输入，通过 2 层卷积层与池化层提取出时间序列的关联特征，再由 SENet 模块对特征图各通道赋予不同权值以对其重要性进行调整，其通过 3 个操作进行，具体实现如下。

1) 挤压操作：采用全局平均池化(global average pooling)层将二维的卷积特征压缩为  $1 \times 1 \times C$  大小的

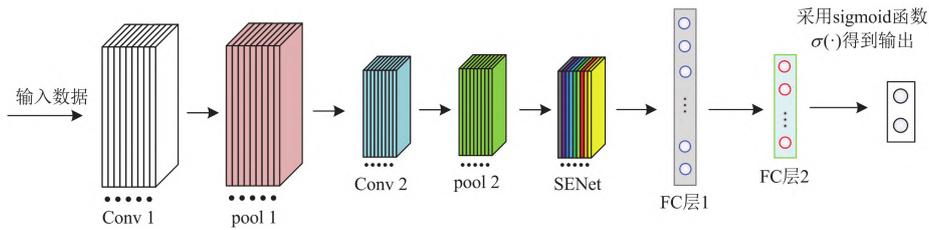


图5 SE-CNN 窃电行为检测模型

Fig. 5 SE-CNN electricity theft behavior detection model

表2 SE-CNN 模型参数设置

Table 2 SE-CNN model parameter setting

参数名称	参数值
卷积核大小	3×3
池化层 pool 1	3×3
池化层 pool 2	2×2
SENet 模块	1
超参数 $r$	16
Dropout 值	0.5
学习率	$1.0 \times 10^{-5}$
训练轮数	Epochs=1000
	Batch_size=1

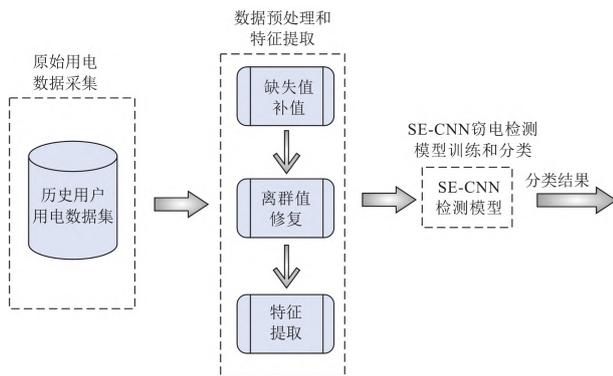


图6 SE-CNN 窃电检测模型实验流程图

Fig. 6 Experimental flow chart of SE-CNN electricity theft detection model

特征图，该转化使每个通道中的特征图都拥有全局感受野，即全局信息。

2) 激励操作：采用全连接层+ReLU 函数+全连接层构建通道之间的相关性，其中第一个全连接层采用缩放系数为  $r$  (最优值为 16) 的  $1 \times 1$  卷积层扫描；然后采用 ReLU 函数进行非线性激活，再次使用全连接层将卷积特征恢复到原始通道数；最后通过 sigmoid 函数的门机制获得 0~1 之间归一化的权重，完成激励操作。

3) 聚合操作：使用 Scale 层把归一化后的权重参数加权到每个通道的特征上，即将挤压操作和激励操作学习到的各个通道的激活值  $S$  和  $U$  的原始特

征相乘，即图 4 的  $F_{scale}(\cdot, \cdot)$  操作。

通过以上操作可让 SE 模块更专注于信息量大的通道特征，抑制无效特征，实现对局部区域进行通道上的特征融合，最后通过全连接层(即图 5 中的 FC 层 1 和 FC 层 2)操作与 sigmoid 分类器得出窃电行为检测结果。

### 3 实验与分析

为验证本文提出算法的有效性和准确性，实验硬件为拥有 64 位 6 核的 Intel Core i7-8750H CPU@2.20 GHz，深度学习框架采用 TensorFlow 和 Keras。本文采用实验数据为南方电网某市电网公司实际数据，该数据集包含从 2009 年 1 月 1 日至 2014 年 12 月 31 日共计 6085 个用户每天用电量数据，该数据分为正常数据和窃电数据，且拥有窃电标签(窃电为“1”，正常为“0”)。其中窃电用户 834 个，占总用户数的 13.7%、该类样本占比较小，数据集存在较为严重的不平衡，会影响模型的训练结果。本文采用随机过采样方法，通过复制少数类示例平衡数据，消除数据不平衡带来的影响，预处理后样本数据集详细描述如表 3 所示，其总用户数 10 291 个，窃电用户 5040 个，占总用户数的 48.97%。

表3 预处理后南方电网数据集

Table 3 Preprocessed dataset of SGC

时间	正常用户数量	窃电用户数量	总用户数量
2009/01/01	5251(51.03%)	5040(48.97%)	10 291(100%)
2014/12/31			

#### 3.1 评价指标构建

南方电网实际数据分为正常用户和窃电用户两类，窃电检测本质为二元分类问题。为衡量检测方法的优劣，可采用混淆矩阵进行验证，其如表 4 所示。根据表 4 的混淆矩阵定义召回率(Recall)和  $F_1$  值，分别对应式(12)和式(13)。

$$R_{\text{recall}} = \frac{T_p}{T_p + F_n} \quad (12)$$

$$F_1 = \frac{2T_p}{2T_p + F_n + F_p} \quad (13)$$

ROC(Receiver Operating Characteristic)曲线用于表示混淆矩阵中  $F_{PR}$  和  $T_{PR}$  增长率之间的相对关系,由表 4 可得  $T_{PR} = T_p/(T_p + F_N)$ 、 $F_{PR} = F_p/(T_N + F_p)$ ,  $F_{PR}$  描述的是预测错误且实际分类为负的数量与所有负样本数量的比例,  $T_{PR}$  描述的是预测正确且实际分类为正的样本数量的比例。

表 4 窃电行为检测中的混淆矩阵

Table 4 Confusion matrix in detection of electricity theft

用户	检测为窃电用户	检测为正常用户
实际窃电用户	$T_p$ (true positive)	$F_N$ (false negative)
实际正常用户	$F_p$ (false positive)	$T_N$ (true negative)

AUC(Area Under ROC Curve)可通过 ROC 曲线下的各部分面积和求得,对于比较各分类器的分类性能, AUC 值越大越好,当 AUC=1 时为理想分类器。AUC 的计算式为

$$A_{UC} = \frac{\sum_{i \in \text{正例}} R_{\text{ank}i} - \frac{M(1+M)}{2}}{M \times N} \quad (14)$$

式中:  $R_{\text{ank}i}$  代表样本  $i$  的排序值;  $M$  为正样本的个数;  $N$  为负样本的个数。

平均精度均值(Mean Average Precision, MAP)用于评估模型检测性能。MAP@ $N$  定义为在前  $N$  个嫌疑度最高的用户中,检测模型正确识别为窃电用户的平均精度均值,即

$$M_{AP@N} = \frac{\sum_{i=1}^r P@k_i}{r} \quad (15)$$

式中:  $r$  代表在前  $N$  个嫌疑度最高的用户中窃电用户的数量;  $P@k_i$  定义为

$$P@k_i = \frac{Y_{k_i}}{k_i} \quad (16)$$

式中:  $Y_{k_i}$  表示在前  $k$  个嫌疑度最高的用户中正确识别窃电用户的数量;  $k_i(i=1,2,3,\dots,r)$  表示  $k$  的位置,本文采用  $M_{AP@100}$  和  $M_{AP@200}$  作为评价指标。

### 3.2 本文方法实验与分析

本文提出 SE-CNN 窃电行为检测方法的输入项包括电量趋势下降指标、线损类指标以及告警类指标,而输出项为窃电标志。针对输入项数据样本进行数据划分,随机选取 50%、60%、70%以及 80%作为训练样本(对应 50%、40%、30%以及 20%数据作为测试样本),并分别进行 4 组实验,基于本文方法在不同训练数据比例的实验结果如表 5 所示。

由表 5 可知,本文提出基于 SE-CNN 窃电行为检测方法在不同训练数据比例下各种评价指标均表现优异, AUC 值达到 0.999 以上。当训练数据和测

试数据比例均为 50%以下时,数据呈现出平衡状态,此时评价指标多数略优于其他训练数据比例,但各种训练数据比例下评价指标结果相差很小,甚至可以忽略,因此本文提出方法表现出良好的泛化性能,能适用于工程实际的复杂电网环境。

表 5 SE-CNN 方法的实验结果

Table 5 Experimental results of the SE-CNN method

评价指标	训练比例为 50%	训练比例为 60%	训练比例为 70%	训练比例为 80%
AUC	0.999 525	0.999 78	0.999 724	0.999 695
$R_{\text{ecall}}$	0.997 086	0.993 927	0.994 494	0.994 172
$F_1$	0.997 086	0.993 928	0.994 495	0.994 174
$M_{AP@100}$	1	1	1	1
$M_{AP@200}$	1	1	1	1

针对 SE-CNN 在实际电网数据下的检测结果进行可视化展示如图 7 所示,其中检测样本数为 6174(占总用户的 60%),预测正确的个数是 6138,预测正确率高达 99.417%,该模型在实际电网数据下检测结果表现优异。

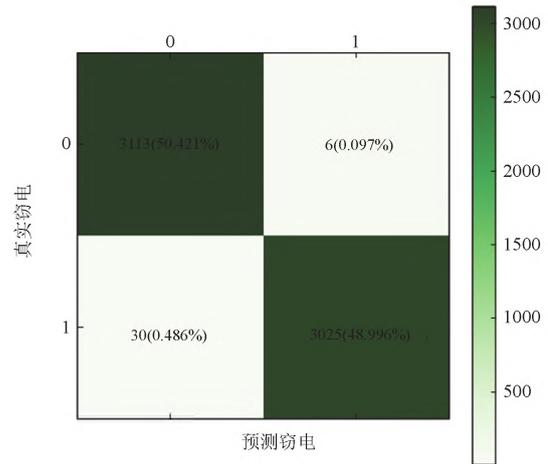


图 7 SE-CNN 模型预测窃电的混淆矩阵图

Fig. 7 Confusion matrix diagram of SE-CNN model predicting electricity theft

为验证注意力机制(SENNet 模块)在 CNN 模型上的改进效果,通过南方电网数据集进行实验测试,随机选取 60%数据作为训练样本,其训练结果如图 8 所示。图 8(a)为 CNN 模型下模型评价指标随遍历次数的增加而变化的情况,该模型需 25 次遍历才能收敛;图 8(b)表示 SE-CNN 模型下模型评价指标随遍历次数的增加而变化的情况,从图 8 中趋势可见,当遍历次数达到 5 次时就完全收敛,因此在 CNN 模型上添加注意力机制使得模型训练效率更高,有效提高模型的检测性能。该模型算法的伪代码图如

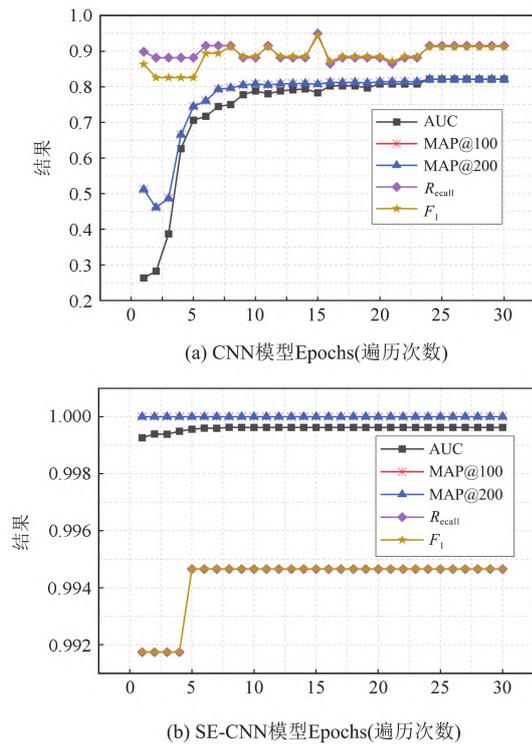


图 8 遍历次数下的模型评价指标图  
Fig. 8 Model metrics diagram by Epochs

Algorithm 1 SE-CNN算法

```

输入: 训练集  $D = \{d_1, d_2, \dots, d_m\}$ 
标签: 属性集  $L = \{l_1, l_2, \dots, l_m\}$ 
#Data processing
1 Input_train = Input [0:Input.len * 80%]
2 Lable_train = Input [0:Input.len * 80%]
#Train
3 While (epoch) do
4     len = input_train.len / batch_size
5     i = 0
6     While (i != len) do
7         #Forward propagation
8         Output_train = Network (Input_train[i * batch_size : (i + 1) * batch_size])
9         #Calculate the loss value
10        Loss = binary_crossentropy(Lable_train[i * batch_size : (i + 1) * batch_size], Output_train)
11        #Backward propagation
12        Loss.Backward
13        #Parameter update
14        Optimizer.step()
15        i = i + 1
16    End
17    epoch = epoch - 1
18 End
#Test
19 输出: Output_test = Network(Input [Lable.len * 80%:Input.len])

```

图 9 SE-CNN 算法的伪代码

Fig. 9 Pseudo-code of SE-CNN algorithm

图 9 所示, 具体描述了该模型算法的工作流程。

### 3.3 与现有方法对比分析

为验证本文提出基于 SE-CNN 窃电行为检测方法的有效性, 本文分别采用 SVM<sup>[16]</sup>、CART 决策树 (Decision Tree)<sup>[17]</sup>、XGboost<sup>[19]</sup>、LM 神经网络<sup>[22]</sup>和 CNN<sup>[27]</sup>这 5 种基于机器学习的检测模型进行比较。本文提出的基于 SE-CNN 窃电行为检测及前述 5 种基于机器学习方法的输入项包括电量趋势下降指标、线损类指标以及告警类指标, 而输出项为窃电标志。针对输入项数据样本进行数据划分, 随机选取 60%和 80%作为训练样本(对应 40%和 20%数据作为测试样本), 并分别进行两组实验, 两组实验数据下不同方法的实验结果如表 6 所示。由表 6 可知, 本文提出方法在实际电网数据下的各项评价指标均好于其他 5 种基于机器学习方法, 而 CNN 方法在这 5 种方法中的大部分指标均优于其他 4 种方法(如 AUC 在两组数据下均达到 0.9, MAP@100 和 MAP@200 均大于 0.929)。

当在 CNN 网络上采用自适应注意力模块(本文采用 SENet 模块)后, 本文构建的 SE-CNN 模型在 CNN 方法的基础上各项指标均大幅提升, 且均达到 0.99 以上, 尤其是 MAP@100 和 MAP@200 这两项

表 6 不同窃电检测方法的结果

Table 6 Results of different electrical theft detection methods

评价指标	训练数据比例(Training ratio)为 60%					
	XGboost	SVM	CART 决策树	LM 神经网络	CNN	本文方法
AUC	0.737 136	0.720 840	0.752 144	0.808 319	0.914 406	0.999 780
$R_{recall}$	0.905 983	0.905 983	0.905 982	0.897 436	0.915 254	0.993 927
$F_1$	0.861 293	0.861 292	0.861 293	0.901 221	0.912 398	0.993 9281
MAP@100	0.739 858	0.634 052	0.619 652	0.820 141	0.821 086	1
MAP@200	0.739 464	0.632 530	0.618 028	0.793 706	0.821 086	1

评价指标	训练数据比例(Training ratio)为 80%					
	XGboost	SVM	CART 决策树	LM 神经网络	CNN	本文方法
AUC	0.865 385	0.766 484	0.809 066	0.810 440	0.901 631	0.999 695
$R_{recall}$	0.881 356	0.881 356	0.881 356	0.881 356	0.932 203	0.994 172
$F_1$	0.825 775	0.825 775	0.825 775	0.884 735	0.919 899	0.994 173
MAP@100	0.689 652	0.705 129	0.731 685	0.815 190	0.816 590	1
MAP@200	0.689 653	0.705 129	0.731 685	0.815 192	0.816 590	1

指标均达到 1。从两组实验数据在本文所提方法的实验表现来看差距很小，因此同时可验证本文方法的泛化性能表现优越。为了进一步验证本文提出的 SE-CNN 窃电行为检测方法的有效性，在训练数据为 60%的情况下，采用 ROC 曲线对所有方法的实验结果进行可视化描述，不同方法的 ROC 曲线如图 10 所示。在 ROC 空间坐标中，越靠近左上 ROC 曲线意味着在同样检测命中率下造成的误检率越低，检测效果越好，本文提出的基于 SE-CNN 窃电行为检测方法 AUC 表现均优于其他方法。本文提出的 SE-CNN 窃电行为检测方法利用卷积神经网络基于卷积运算自动提取用户用电数据高维深层特征；通过在卷积神经网络上添加 SENet 通道注意力

模块，使模型抑制其他无效特征，实现对局部区域通道上的特征融合，可更快达到拟合状态。由此可见，本文提出方法相比于现有几种机器学习方法具有更高的模型训练效率和识别准确度。

#### 4 结论

本文提出了基于通道注意力网络改进卷积神经网络模型的窃电行为检测方法，实现了实际电网情况下窃电行为的准确检测，实验结果表明：通过建立窃电评价指标体系，提取电量趋势下降指标、线损指标以及与其窃电相关的终端报警类指标特征，可减少输入数据维度，更明显表征窃电行为规律；在 CNN 模型基础上引入了 SENet 自适应注意力机制，使模型聚焦特征表达更有效的特征通道、并抑制无效的特征通道，提升了模型的检测准确度；相比于现有检测方法，本文提出方法的检测精度更高、实用性强，表现出良好的泛化性能，为当前智能电网发现异常用电行为、稽查窃电用户提供准确有效的检测手段，降低企业运营成本，保证电网可靠安全运行。

#### 参考文献

- [1] VIEGAS J L, ESTEVES P R, MELÍCIO R, et al. Solutions for detection of non-technical losses in the electricity grid: a review[J]. Renewable and Sustainable Energy Reviews, 2017, 80: 1256-1268.
- [2] 万磊, 陈成, 黄文杰, 等. 基于 BRB 和 LSTM 网络的电

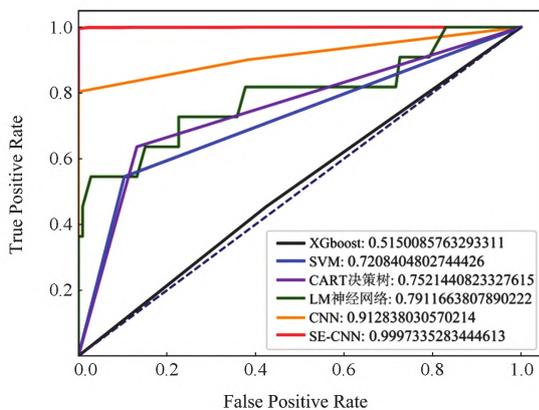


图 10 不同方法的 ROC 曲线

Fig. 10 ROC curve of different methods

- 力大数据用电异常检测方法[J]. 电力建设, 2021, 42(8): 38-45.
- WAN Lei, CHEN Cheng, HUANG Wenjie, et al. Power abnormality detection method based on power big data applying BRB and LSTM network[J]. Electric Power Construction, 2021, 42(8): 38-45.
- [3] MASSAFERRO P, MARTINO J M D, FERNÁNDEZ A. Fraud detection in electric power distribution: an approach that maximizes the economic return[J]. IEEE Transactions on Power Systems, 2020, 35(1): 703-710.
- [4] 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.
- [5] 招景明, 唐捷, 潘峰, 等. 基于 SDAE 和双模型联合训练的低压用户窃电检测方法[J]. 电测与仪表, 2021, 58(12): 161-168.
- ZHAO Jingming, TANG Jie, PAN Feng, et al. Detection method of electricity theft for low-voltage users based on SDAE and double-model joint training[J]. Electrical Measurement & Instrumentation, 2021, 58(12): 161-168.
- [6] 武超飞, 孙冲, 刘厦, 等. 基于改进 FCM 聚类的窃电行为检测[J]. 电力科学与技术学报, 2021, 36(6): 164-170.
- WU Chaofei, SUN Chong, LIU Sha, et al. Detection of stealing electricity energy based on improved fuzzy C-means clustering[J]. Journal of Electric Power Science and Technology, 2021, 36(6): 164-170.
- [7] RAZAVI R, GHARIPOUR A, FLEURY M, et al. A practical feature-engineering framework for electricity theft detection in smart grids[J]. Applied Energy, 2019, 238: 481-494.
- [8] 保富, 黄祖源. 基于流计算的大客户用能智能分析方法[J]. 电力系统保护与控制, 2021, 49(11): 148-154.
- BAO Fu, HUANG Zuyuan. Intelligent analysis method for energy consumption of large customers based on stream computing[J]. Power System Protection and Control, 2021, 49(11): 148-154.
- [9] 孙毅, 李世豪, 崔灿, 等. 基于高斯核函数改进的电力用户用电数据离群点检测方法[J]. 电网技术, 2018, 42(5): 1595-1606.
- SUN Yi, LI Shihao, CUI Can, et al. Improved outlier detection method of power consumer data based on Gaussian kernel function[J]. Power System Technology, 2018, 42(5): 1595-1606.
- [10] 户艳琴, 李海明, 刘念, 等. 面向能源互联网终端用户的异常数据检测方法[J]. 电力建设, 2021, 42(10): 19-27.
- HU Yanqin, LI Haiming, LIU Nian, et al. Detection method of abnormal data for end users of energy internet[J]. Electric Power Construction, 2021, 42(10): 19-27.
- [11] 程超, 张汉敬, 景志敏, 等. 基于离群点算法和用电信息采集系统的反窃电研究[J]. 电力系统保护与控制, 2015, 43(17): 69-74.
- CHENG Chao, ZHANG Hanjing, JING Zhimin, et al. Study on the anti-electricity stealing based on outlier algorithm and the electricity information acquisition system[J]. Power System Protection and Control, 2015, 43(17): 69-74.
- [12] 庄池杰, 张斌, 胡军, 等. 基于无监督学习的电力用户异常用电模式检测[J]. 中国电机工程学报, 2016, 36(2): 379-387.
- ZHUANG Chijie, ZHANG Bin, HU Jun, et al. Anomaly detection for power consumption patterns based on unsupervised learning[J]. Proceedings of the CSEE, 2016, 36(2): 379-387.
- [13] 王德文, 杨凯华. 基于生成式对抗网络的窃电检测数据生成方法[J]. 电网技术, 2020, 44(2): 775-782.
- WANG Dewen, YANG Kaihua. A data generation method for electricity theft detection using generative adversarial network[J]. Power System Technology, 2020, 44(2): 775-782.
- [14] TAKIDDIN A, ISMAIL M, ZAFAR U, et al. Robust electricity theft detection against data poisoning attacks in smart grids[J]. IEEE Transactions on Smart Grid, 2021, 12(3): 2675-2684.
- [15] MESSINIS G M, RIGAS A E, HATZIARGYRIOU N D. A hybrid method for non-technical loss detection in smart distribution grids[J]. IEEE Transactions on Smart Grid, 2019, 10(6): 6080-6091.
- [16] NAGI J, YAP K S, TIONG S K, et al. Improving SVM-based nontechnical loss detection in power utility using the fuzzy inference system[J]. IEEE Transactions on Power Delivery, 2011, 26(2): 1284-1285.
- [17] JINDAL A, DUA A, KAUR K, et al. Decision tree and SVM-based data analytics for theft detection in smart grid[J]. IEEE Transactions on Industrial Informatics, 2016, 12(3): 1005-1016.
- [18] 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.
- [19] YAN Z, WEN H. Electricity theft detection base on extreme gradient boosting in AMI[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-9.
- [20] 陈钢, 李德英, 陈希祥. 基于改进 XGBoost 模型的低误报率窃电检测方法[J]. 电力系统保护与控制, 2021, 49(23): 178-186.  
CHEN Gang, LI Deying, CHEN Xixiang. Detection method of electricity theft with low false alarm rate based on an XGBoost model[J]. Power System Protection and Control, 2021, 49(23): 178-186.
- [21] 巢政, 温蜜. 一种基于 SMOTE 和 XGBoost 的窃电检测方案[J]. 智慧电力, 2020, 48(11): 97-102.  
CHAO Zheng, WEN Mi. Scheme for electricity theft detection based on SMOTE and XGBoost[J]. Smart Power, 2020, 48(11): 97-102.
- [22] BUZAU 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.
- [23] 林晓静, 刘文, 甘超飞, 等. 基于卷积神经网络与多维度电力大数据的信用评估系统[J]. 电测与仪表, 2021, 58(11): 101-106.  
LIN Xiaojing, LIU Wen, GAN Chaofei, et al. Corporate credit assessment system based on convolutional neural network and multi-dimensional power big data[J]. Electrical Measurement & Instrumentation, 2021, 58(11): 101-106.
- [24] 赵文清, 沈哲吉, 李刚. 基于深度学习的用户异常用电模式检测[J]. 电力自动化设备, 2018, 38(9): 34-38.  
ZHAO Wenqing, SHEN Zheji, LI Gang. Anomaly detection for power consumption pattern based on deep learning[J]. Electric Power Automation Equipment, 2018, 38(9): 34-38.
- [25] 张静, 尚光伟, 龚正国, 等. 计及负荷分类及其需求响应的配电网设备利用率提高方法[J]. 电网与清洁能源, 2021, 37(2): 50-56, 63.  
ZHANG Jing, SHANG Guangwei, GONG Zhengguo, et al. An optimization method of distribution network equipment utilization considering load classification and demand response[J]. Power System and Clean Energy, 2021, 37(2): 50-56, 63.
- [26] HE Y, MENDIS G J, WEI J. Real-time detection of false data injection attacks in smart grid: a deep learning-based intelligent mechanism[J]. IEEE Transactions on Smart Grid, 2017, 8(5): 2505-2516.
- [27] LI S, HAN Y, YAO X, et al. Electricity theft detection in power grids with deep learning and random forests[J]. Journal of Electrical and Computer Engineering, 2019, 1-12.
- [28] ZHENG Z, YANG Y, NIU X, 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.
- [29] DESAI J P, MAKWANA V H. A novel out of step relaying algorithm based on wavelet transform and a deep learning machine model[J]. Protection and Control of Modern Power Systems, 2021, 6(4): 500-511.
- [30] 郑炜, 林瑞全, 王俊, 等. 基于 GAF 与卷积神经网络的电能质量扰动分类[J]. 电力系统保护与控制, 2021, 49(11): 97-104.  
ZHENG Wei, LIN Ruiquan, WANG Jun, et al. Power quality disturbance classification based on GAF and a convolutional neural network[J]. Power System Protection and Control, 2021, 49(11): 97-104.
- [31] 刘佳翰, 陈克绪, 马建, 等. 基于卷积神经网络和随机森林的三相电压暂降分类[J]. 电力系统保护与控制, 2019, 47(20): 112-118.  
LIU Jiahao, CHEN Kexu, MA Jian, et al. Classification of three-phase voltage dips based on CNN and random forest[J]. Power System Protection and Control, 2019, 47(20): 112-118.
- [32] TAKIDDIN A, ISMAIL M, NABIL M, et al. Detecting electricity theft cyber-attacks in AMI networks using deep vector embeddings[J]. IEEE Systems Journal, 2021, 15(3): 4189-4198.
- [33] 周飞燕, 金林鹏, 董军. 卷积神经网络研究综述[J]. 计算机学报, 2017, 40(6): 1229-1251.  
ZHOU Feiyan, JIN Linpeng, DONG Jun. Review of convolutional neural network[J]. Chinese Journal of Computers, 2017, 40(6): 1229-1251.

收稿日期: 2022-01-17; 修回日期: 2022-04-06

作者简介:

夏睿(1991—), 男, 博士研究生, 研究方向为智能信息处理、人工智能在电力系统大数据中的应用; E-mail: xiarui536@hnu.edu.cn

高云鹏(1978—), 男, 通信作者, 博士, 教授, 博士生导师, 研究方向为智能信息处理、人工智能在电力系统大数据中的应用。E-mail: gaoyunpeng@hnu.edu.cn

(编辑 周金梅)