

# 基于深度混合注意力网络的窃电检测

彭军<sup>1</sup>,李琪林<sup>1</sup>,周尧<sup>2</sup>,袁钟<sup>2</sup>,彭德中<sup>2</sup>,刘益志<sup>2</sup>

(1. 国网四川省电力公司营销服务中心, 四川 成都 610045;

2. 四川大学计算机学院, 四川 成都 610065)

**摘要:**窃电检测旨在识别和检测非法或未经授权的电力使用行为。在智能电网技术高速发展的背景下,如何实现准确的窃电行为检测,是学术界和工业界广泛关注的一个重要问题。针对已有方法依赖人工特征设计以及低层特征提取能力不足的问题,提出了一种基于深度混合注意力网络的窃电检测方法,将通道注意力和自相关注意力机制相结合,在不同层次和空间范围内捕捉数据中的时间依赖性和周期性等复杂特征。所提模型在低层使用通道注意力网络来增强低层特征的表达能力,在中间层使用自相关注意力来捕捉全局上下文信息,并利用自监督方法来学习注意力参数,从而提取出更具表达力和判别力的特征表示。在中国国家电网数据集上进行实验所获得的结果表明,所提出的方法在AUC以及F1等性能指标上取得了更好的效果。

**关键词:**窃电检测; 智能电网; 混合注意力网络; 自监督学习

中图分类号:TP 391 文献标志码:A 文章编号:1003-6954(2024)02-0099-08

DOI:10.16527/j.issn.1003-6954.20240217

## Electricity Theft Detection Based on Deep Hybrid Attention Networks

PENG Jun<sup>1</sup>, LI Qilin<sup>1</sup>, ZHOU Yao<sup>2</sup>, YUAN Zhong<sup>2</sup>, PENG Dezhong<sup>2</sup>, LIU Yizhi<sup>2</sup>

(1. Marketing Service Center of State Grid Sichuan Electric Power Company, Chengdu 610045, Sichuan, China; 2. College of Computer Science, Sichuan University, Chengdu 610065, Sichuan, China)

**Abstract:** Electricity theft detection aims to identify and detect unauthorized or illegal electricity usage. In the context of rapid development of smart grid, achieving accurate electricity theft detection has become an important concern in both academia and industry. Aiming at the limitations of existing methods, which rely on manual feature design and have insufficient capability in low-level feature extraction, an electricity theft detection method based on deep hybrid attention network is proposed. The proposed model combines channel attention and self-attention mechanisms to capture complex features such as temporal dependencies and periodicity across different levels and spatial ranges in the data. Specifically, the model enhances the expression of low-level features using a channel attention network in the low layers, captures global contextual information using self-attention in the middle layers, and learns attention parameters through self-supervised learning to extract more expressive and discriminative feature representations. Experimental results on the national power grid dataset demonstrate that the proposed method can achieve better performance in terms of AUC and F1 scores.

**Key words:** electricity theft detection; smart grid; hybrid attention network; self-supervised learning

## 0 引言

窃电检测,又称为异常用电行为检测,旨在识别和检测非法或未经授权的电力使用行为<sup>[1]</sup>。窃电行为不仅造成巨额经济损失,而且对公共用电安全造成严重威胁。在用电需求遍及各个行业以及日

基金项目:国网四川省电力公司科技项目“基于认知计算的异常用电行为智能分析技术研究”(521997230015)

常生活的背景下,研究高效准确的窃电检测方法对于保障电力供应安全、促进电网可靠运行和维护电力企业的经济利益等方面具有重要意义。

随着智能电能表等基础电力设施的发展,获取大规模电压、电流、能源使用情况等数据成为可能。近年来,已有许多研究提出使用机器学习方法对电力数据进行分析 and 检测,比如随机森林(random forest, RF)、极度梯度提升树(extreme gradient boosting,

XGBoost) 以及支持向量机 (support vector machine, SVM) 等<sup>[2]</sup>。这些方法通过数据驱动的形式学习一个判别模型来进行窃电预测。但是, 由于智能电表、电网传感器的广泛使用, 用电行为数据呈现出维度高、数据模式稀疏等特点, 传统机器学习方法难以提取有效深层特征, 限制了窃电检测的性能提升<sup>[3]</sup>。

特征提取对于窃电检测模型的性能具有重要影响, 而在传统机器学习算法中, 该过程非常依赖于专家经验和领域知识, 比如用电波动趋势、变动趋势、升降趋势等<sup>[4]</sup>。这些手工设计的特征难以有效提取用电数据中蕴含的模式, 容易导致潜在特征的丢失。深度学习方法通过构建深层的神经网络结构, 实现了自动的特征提取, 从而消除了对于人工特征设计的依赖, 同时能够实现对数据中深层隐含特征的提取, 从而取得更好的检测效果<sup>[5]</sup>。然而, 由于用电数据时间跨度大, 异常特征稀疏, 现有深度学习方法对于有效特征的提取能力仍有待进一步提升, 从而实现更加准确的窃电检测。

为了更好地从长时间跨度用电数据中有效提取稀疏的异常模式特征, 提出一种基于深度混合注意力网络的窃电检测模型 (deep hybrid attention networks for electricity theft detection, HAND), 将通道注意力和自相关注意力机制相结合, 在不同层次和空间范围内捕捉数据中的时间依赖性和周期性等复杂特征。具体而言, 该模型在低层使用通道注意力参数进行用电行为特征提取增强, 通过特征权重实现对特征的精炼; 在中间层使用自相关注意力来捕捉全局上下文信息, 并利用自监督方法来学习注意力参数, 从而提取出更具表达力和判别力的特征表示。在中国国家电网数据集上的实验结果表明, 所提出的 HAND 模型获得了更好的效果, 从而验证了所提出的窃电检测方法的有效性。

## 1 已有窃电检测方法

数据驱动的窃电检测方法大致可以分为两类: 基于机器学习的方法以及基于深度学习的方法。

### 1.1 机器学习

文献[6]针对非技术性电力损失, 提出了一种基于支持向量机的窃电检测方法, 首先, 对用电数据进行预处理、特征选择、归一化等一系列操作; 然后, 构建一个使用 RBF 核的二分类支持向量机来进行异常用电行为识别, 获得了显著的检测准确率提升。

此外, 文献[7]中提出了一种基于极限学习机 (extreme learning machine, ELM) 的异常用电检测方法, 该方法具有非常快的学习能力, 在引入非线性函数的同时, 无须设定停止准则、学习率、学习轮数, 可以避免陷入局部最优, 并且实验结果表明该方法获得了比支持向量机方法更高的异常行为检测准确率。文献[8]中提出了一种基于决策树的异常用电行为识别方法, 将单位窗口期线损率阈值作为根节点, 构建具有二叉树状结构的决策树, 从而确定窃电行为的具体线路信息。此外, 聚类方法也被运用于窃电行为的检测, 比如文献[9]中提出了一种改进的 K-means 算法, 通过计算数据点到聚类中心的平均距离作为异常度, 取得了良好的检测准确率。尽管基于机器学习的方法取得了一定的成功, 但对于人工特征设计的依赖难以保证它在实际应用中的效果, 并且检测准确率仍有待进一步提升。

### 1.2 深度学习

深度学习方法也被广泛地运用于窃电检测<sup>[10]</sup>。文献[11]提出一种基于长短时记忆网络 (long short-term memory, LSTM) 的方法, 将用电数据作为序列信息进行处理, 有效实现了窃电行为的检测。文献[12]中, 稀疏性和噪声被引入到堆叠的自编码器中, 用于增强该模型对于用电行为数据的特征提取能力, 并且通过粒子群 (particle swarm optimization, PSO) 方法来优化模型中的超参数。作为图像处理领域最为成功的深度学习模型之一, 卷积神经网络 (convolutional neural network, CNN) 也被运用到了窃电行为识别领域<sup>[13-14]</sup>。

文献[15]提出了一种叫作 TBDA-Net 的深度神经网络模型, 并且使用领域自适应思想来克服窃电检测任务中的小样本问题<sup>[16]</sup>。实际上, 用电数据也是一种时序数据, 许多成功的基于深度神经网络的序列分析方法可以被用于窃电检测。文献[17]中提出了一种基于自相关注意力机制的窃电检测方法, 该方法使用自相关注意力机制 (self-attention) 更好地提取全局特征信息, 并且结合使用 CNN 提取局部特征信息, 有效提升了窃电检测的准确率。文献[18]指出用电数据中存在的二阶信息没有被充分利用, 进而提出了一阶二阶混合的特征表达学习网络, 更好地建模用电数据中全局和局部的时序依赖。尽管这些方法取得了较好的效果, 但是随着模型深度的增加<sup>[19-20]</sup>, 特征提取能力容易产生退化。

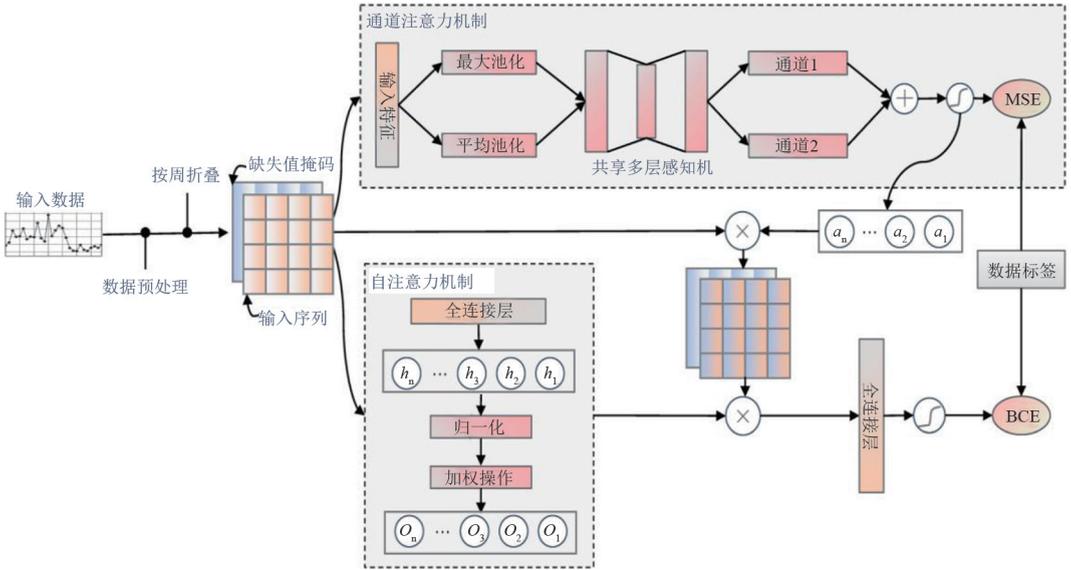


图 1 基于深度混合注意力网络的窃电检测模型

## 2 窃电检测框架

针对已有窃电检测方法的不足,提出了一种基于深度混合注意力网络的窃电检测方法,其框架由两个部分组成:混合注意力特征提取网络和注意力参数自监督学习方法。

### 2.1 混合注意力特征提取网络

网络模型如图 1 所示,通道注意力通过学习和卷积层特征通道数量相同的一组参数,实现对卷积层特征通道的重要性加权,从而提取出和任务更加相关的卷积层通道特征。对于一个给定的卷积层,假设其中的特征图使用  $F$  来表示,则  $F_k^l(x, y)$  表示第  $l$  层第  $k$  个通道  $(x, y)$  位置的激活值。类似的,第  $k$  个通道的注意力权重使用  $w_k$  来表示,因此经过通道注意力特征提取以后第  $(l+1)$  层的卷积层特征图可以表示为

$$F_k^{l+1}(x, y) = w_k \cdot F_k^l(x, y) \quad (1)$$

通道注意力的权重可以用于融合用电行为数据的卷积层特征,并进行异常行为结果预测。而通道注意力权重的学习可以在浅层网络中增加额外的预测分支并进行训练来实现,不仅可以减少网络层数过多带来的监督信号衰减,而且可以使得通道注意力权重的学习和用电行为异常检测任务更具关联性,从而强化网络在低层特征提取时对用电行为抽象语义特征的关注度。基于通道注意力的预测分支的输出可以表示为

$$S = \sigma \left[ \sum_k w_k \cdot P(F_k^l) \right] \quad (2)$$

式中: $P()$ 为均值池化; $\sigma()$ 的计算方式可以表示为

$$\sigma(x) = \frac{1}{1 + \exp(-x)} \quad (3)$$

进而,使用交叉熵损失函数(cross-entropy loss)来计算整个用电行为数据集上该预测分支输出  $S$  和真实标签  $Y$  之间的平均差异,具体计算为

$$L_1 = \frac{1}{N} \sum_{i=1}^N - Y^i \log_2 S^i + (1 - Y^i) \log_2 (1 - S^i) \quad (4)$$

式中: $N$ 为样本的总数; $S^i$ 和 $Y^i$ 分别为第 $i$ 个样本的输出和真实标签。

此外,用电数据在时间上存在明显的周期性特征,并且已有研究表明这些周期特性呈现较强的自相关性<sup>[17]</sup>。从模型结构上进行相应的设计,可以更有效地利用这些周期性特征,实现更加准确的用电行为异常检测。一般来说,用电数据可以被看成一种时序数据,使用  $n$  来表示其长度。假设数据的周期为  $W$ ,则该数据维度可以变换为  $W \times \frac{n}{W}$ 。进而,两个周期特征之间的自相关注意力  $A$  可以通过点积来计算。

$$A(l, j) = \sum_{k=1}^{n/W} F(l, k) \cdot F(j, k) \quad (5)$$

式中: $A(l, j)$ 为第 $l$ 个周期和第 $j$ 个周期之间的注意力权重系数; $F(l, k)$ 和 $F(j, k)$ 分别为第 $l, j$ 个周期的第 $k$ 个元素。

得到用电数据特征的自相关注意力以后,可以对模型通过通道注意力提取的特征进行融合,从而实现通道注意力和自相关注意力机制的合并。具体合并方法通过矩阵乘法以及卷积来实现。

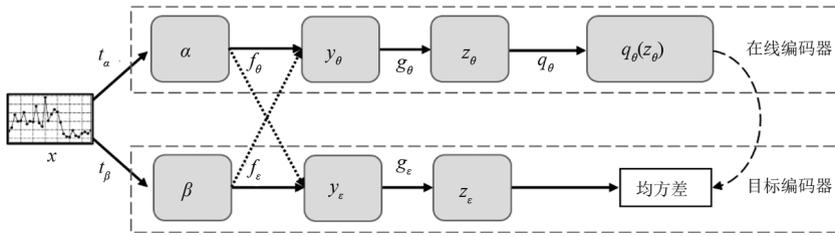


图 2 注意力参数自监督学习方法

$$\bar{Y} = A \otimes F \quad (6)$$

式中,  $\bar{Y}$  为融合后的特征表示。

最后,再次使用交叉熵损失函数来计算模型预测的用电行为异常情况和真实标签之间的差异,具体计算可以表示为

$$L_2 = \frac{1}{N} \sum_{i=1}^N -Y^i \log_2 \bar{Y}^i + (1 - Y^i) \log_2 (1 - \bar{Y}^i) \quad (7)$$

式中,  $\bar{Y}^i$  为第  $i$  个样本的预测标签。

因此整个窃电检测预测模型的优化可以通过最小化两个损失函数之和来实现,可以记作

$$\min(\lambda_1 L_1 + \lambda_2 L_2) \quad (8)$$

式中,  $\lambda_1$  和  $\lambda_2$  分别为损失函数两个组成部分的权重,用于控制模型优化过程中对于通道注意力权重的学习和模型整体参数学习两个目标之间的权衡。

## 2.2 注意力参数自监督学习方法

由于数据规模以及标签质量等因素的影响,有监督的判别学习范式难以捕获用电数据的抽象特征,通过自监督学习模式可以学习到更加鲁棒的用电数据特征。注意力机制的参数对于用电行为的特征提取至关重要,于是提出使用自监督学习方法来进行注意力参数的特征学习,如图 2 所示。对于给定的用电数据  $x$ ,使用两种数据变换方法  $t_\alpha$  和  $t_\beta$  来分别产生新的不同视角的数据  $\alpha$  和  $\beta$ ,接着使用所提出的注意力特征提取网络  $f_\theta$  和  $f_\xi$  ( $\theta$  和  $\xi$  为其对应的参数)分别提取出用电数据特征  $y_\theta$  和  $y_\xi$ 。为了减小特征匹配的难度,进一步引入  $g_\theta$  和  $g_\xi$  作为映射网络,辅助注意力特征提取网络将不同视角的用电行为特征,在深层语义空间中映射到相近位置。进一步,为了避免在线编码器和目标编码器在自监督学习过程中形成对称关系,对于在线编码器额外添加一个预测器网络  $q_\theta$ ,从而进一步对提取到的用电数据特征进行辅助变换。对于在线编码器的输出  $q_\theta(z_\theta)$  以及目标编码器的输出  $z_\xi$ ,使用均方差作为损失函数来指导整个模型的训练,其具体形式为

$$L_{\theta,\xi} = \|q_\theta(z_\theta, \alpha) - z_\xi(\beta)\|_2^2 \quad (9)$$

此外,通过将  $\alpha$  和  $\beta$  交换顺序后分别输入到注意力特征提取网络  $f_\xi$  和  $f_\theta$  中,可以得到另外一组特征预测输出  $q_\theta(z_\theta, \beta)$  和  $z_\xi(\alpha)$ ,类似地使用均方差作为损失函数来衡量在线编码器和目标编码器所提取的用电数据特征的相似程度,其计算式为

$$L'_{\theta,\xi} = \|q_\theta(z_\theta, \beta) - z_\xi(\alpha)\|_2^2 \quad (10)$$

因此,对于在线编码器的参数  $\theta$ ,其优化目标为

$$\min_{\theta} (L_{\theta,\xi} + L'_{\theta,\xi}) \quad (11)$$

而对于目标编码器的参数  $\xi$ ,通过动量的方式来更新,具体可以表示为

$$\xi \leftarrow \tau \xi + (1 - \tau) \theta \quad (12)$$

式中,  $\tau$  为动量更新方式的学习率。

自监督学习方法训练完成以后,仅保留在线编码器中的注意力特征提取网络  $f_\theta$  中的注意力参数部分,丢弃目标编码器部分。对于注意力特征提取网络中的其他参数的优化,通过式(11)来实现。

## 3 实验

### 3.1 实验数据

为了验证所提出的窃电检测方法的有效性,进一步在中国国家电网数据集上进行实验验证<sup>[1]</sup>。该数据集包含从 2014 年 1 月至 2016 年 10 月共计 1035 天内 42 372 位用户的用电记录。经过专业人员的标注,其中有 3615 位用户的用电数据被认定为异常用电,剩余其他用户的用电数据被认定为正常用电。具体的数据分布情况如表 1 所示。

表 1 用电数据分布情况

项目	数据
总用电用户数	42 372
正常用电用户数	38 757 (91.5%)
异常用电用户数	3615 (8.5%)
时间范围	2014 年 1 月 1 日—2016 年 10 月 31 日
数据缺失比例	25.7%

### 3.2 数据预处理

由于电网数据测量以及记录过程中存在的误差,实际的电网数据中存在大量的噪声和数据缺失问题,因此对数据进行预处理是进行后续分析的首要步骤。假设  $v_m$  为数据集中  $m$  日的用电记录,  $\eta$  为不可用的数据记录,对于相邻的记录是有效数据的情况,进行均值插值处理,而相邻记录均为无效数据的情况下,进行填零处理,该过程表示为

$$f(v_m) = \begin{cases} \frac{v_{m+1} + v_{m-1}}{2}, & v_{m+1}, v_{m-1} \neq \eta \\ 0, & v_{m+1}, v_{m-1} = \eta \end{cases} \quad (13)$$

由于有效用电数据中也存在大量为 0 或者接近 0 的记录,因此对异常值直接进行填 0 或者插值操作会引入数据偏差。为了避免这个问题,对于经过填 0 的用电数据记录,对其位置使用二值掩码  $M$  进行标记,该过程可以表示为

$$M(v_m) = \begin{cases} 1, & v_m = \eta \\ 0, & v_m \neq \eta \end{cases} \quad (14)$$

对于填 0 处理后的数据,使用归一化方法来处理其属性值,可以进一步减少异常值导致的模型训练收敛慢的问题。尽管目前有很多归一化方法可用,但综合考虑计算效率以及数据属性特征,使用最大最小归一化方法,该方法如式(15)所示。

$$f_{\text{std}}(x_m) = \frac{x_m - \min(X)}{\max(X) - \min(X)} \quad (15)$$

式中:  $\min(\cdot)$  和  $\max(\cdot)$  分别为求最小值和最大值;  $X$  为整个用电行为数据集。经过填充后的数据和对应的二进制掩码共同构成两个通道的数据形式。将数据以周为时间单位进行折叠,最终构建出的数据维度为  $2 \times 148 \times 7$ ,其中 148 和 7 等价于图像的高度和宽度属性。

### 3.3 评价指标

为了评估所提出的窃电检测方法的准确性,采用异常检测任务中常见的 F1、AUC (area under curve) 以及平均精度均值 (mean average precision, MAP) 作为评价指标对窃电检测方法的性能进行评估。MAP 首先根据预测得分对测试集的标注信息进行排序,然后按式(16)计算在前  $K$  条数据上的精度。

$$P_{\text{MAP@}K} = \frac{Y_K}{K} \quad (16)$$

式中,  $Y_K$  为  $K$  条数据中正确预测的用电行为数据样本的数量。

### 3.4 实验设置

所做的实验均在 NVIDIA GeForce RTX 3090

GPU 的服务器上进行,模型训练的数据批大小为 64,学习率设置为 0.001,使用 Adam 优化器来更新模型参数。对于式(8)中的  $\lambda_1$  和  $\lambda_2$ ,分别设置为 0.005 和 1.000,而式(12)中的  $\tau$  设置为 0.99 来维持一个较慢的动量更新速度。对于给定的用电数据,输入到模型之前首先会在时间维度上以周为单位进行折叠,从而构建出二维数据输入。结合缺失数据的 mask 标记,形成两个数据通道。所提出的神经网络模型首先采用卷积核数量分别为 64 和 128 的两个分组卷积层进行低级特征提取。对于通道注意力部分,使用均值池化方式构建特征向量,并且通过和通道注意力参数进行内积计算得到用电行为为异常情况的得分预测,该预测并不作为最后的检测结果,而是为学习通道注意力参数以及增强低层特征提取提供监督信号。另一方面,卷积层提取到的特征图张量通过维度变换,将以周为单位的时间维度转换到张量的最后一维,通过爱因斯坦求和 (Einstein summation) 方法对原特征张量和该张量自身在最后一个维度计算内积,形成的注意力矩阵再与经过通道注意力加权后的卷积特征图相乘。最后的一个卷积层使用 100 个卷积核,然后通过一个  $100 \times 1$  的全连接层映射到一维输出,并且使用 Sigmoid 函数得到最终的用电行为异常度的预测。自监督学习部分的映射网络  $g_\theta$  和  $g_\xi$  以及预测器网络  $q_\theta$  均使用一个隐层大小为 128 单隐层的全连接神经网络。数据变换方法为在原始用电数据上增加一个服从均值为 0、方差为 0.01 的高斯随机噪声。

### 3.5 实验结果

将训练数据按照 6:2:2 和 8:1:1 两种不同的比例将数据集分别划分为训练集、验证集以及测试集,并对所提出的 HAND 方法进行验证,并且和多种其他的窃电检测方法进行对比,通过选择在验证集上取得最好效果的模型,并用前面所述的评价指标来评估各个模型在测试集上取得的效果,具体实验结果如表 2 所示。通过和包括逻辑回归 (logistic regression, LR)<sup>[2]</sup>、SVM<sup>[6]</sup>、RF<sup>[8]</sup>、XGBoost<sup>[2]</sup>、ELM<sup>[7]</sup>、去噪自动编码器 (sparse autoencoders, SAE)<sup>[12]</sup> 以及 CNN<sup>[1]</sup> 在内的窃电检测方法进行比较和分析可以发现,所提出的 HAND 方法在 6:2:2 的数据集划分情况下,在 AUC、F1、MAP@100 以及 MAP@200 指标上获得了 91.4、58.5、98.6 以及 98.0 的性能,并且在 8:1:1 的数据集划分情况下,在这些指标上获得了 97.0、62.8、99.6 以及 97.7 的性能。这些结果均优于所比较的其他窃电检测方法,这表明所提出的方法在异常用

电检测方面可以取得更好的效果。此外,也可以发现,相比 LR、SVM、RF 等机器学习方法,所提出的 HAND 模型的效果具有明显优势,一个主要的原因是 HAND 模型不需要手工构建数据特征,可以以端到端的方式进行学习,因此可以更有效地提取异常用电行为数据的特征。相比基于深度神经网络的 SAE 和 CNN 方法,所提出的方法也取得了更好的效果,这表明使用混合注意力机制可以更进一步提升卷积层的特征提取能力。

### 3.6 消融实验

为了进一步验证所提 HAND 模型的有效性,对模型中通道注意力以及自相关注意力两个分支进行消融实验。实验方法为:将注意力向量或者注意力张量在前向计算的过程中固定为常数 1,即可避免其对模型最终输出产生影响。在不同的数据集划分比例情况下得到的实验结果如表 3 所示,wo-CA 表示未使用通道注意力分支,wo-SA 表示未使用自相关注意力分支,可以看到在未使用通道注意力(wo-CA)以及自相关注意力(wo-SA)的情况下,模型的性能出现了显著下降。此外,在只使用其中一种注意力机制的情况下,只使用通道注意力(wo-SA)带来的性能提升相比于只使用自相关注意力(wo-CA)更大,这表明通道注意力可以更好地提升模型对于异常用电行为数据的特征提取能力。另外一种可能的原因是通道注意力引入了一组可学习

的参数来表达注意力,因此一定程度上会扩充模型的能力。而自相关注意力主要是通过数据自身的相关性来表达,因此更多是从数据本身来提升数据特征的表达能力。由此可以推断两种注意力可以分别从参数和数据的角度来增强模型的特征提取能力,并且从实验结果可以看出,两种注意力机制同时使用的时候,在 AUC、F1、MAP@100 以及 MAP@200 指标上均取得了最好的性能。该实验结果表明,通道注意力可以带来更加显著的性能提升,并且同时使用两种注意力机制才能获得更好的检测性能。此外,对于不使用自监督学习方法(wo-SL)来学习注意力参数的情况,用电异常行为检测的性能在各个指标上均产生了一定程度的下降,这表明自监督学习方法可以实现更加鲁棒的注意力参数的学习,从而获得更加准确的窃电检测结果。

### 3.7 参数分析

模型训练阶段需要设定两个超参数  $\lambda_1$  和  $\lambda_2$  来平衡通道注意力部分的损失函数优化以及模型最后输出的误差优化。因此进一步对这两个参数的设定进行分析,通过调节  $\lambda_1$  的值,并固定  $\lambda_2 = 1$ ,得到的实验结果如图 3 所示。可以看到, $\lambda_1$  的取值为 0.005 的时候取得最好的检测性能,因此选择 0.005 设置为模型训练阶段  $\lambda_1$  参数的取值。

此外,通过调整式(12)中的动量更新参数  $\tau$  的取值,得到的实验结果如图 4 所示,因此自监督学习

表 2 多种窃电检测方法在中国国家电网数据集上的性能比较

方法	训练集-验证集-测试集比例 6:2:2				训练集-验证集-测试集比例 8:1:1			
	AUC	F1	MAP@100	MAP@200	AUC	F1	MAP@100	MAP@200
LR	67.2	41.5	65.4	56.8	70.6	46.7	65.6	57.8
SVM	72.4	46.7	70.9	60.0	74.1	48.4	73.5	62.0
RF	73.9	46.9	90.8	86.6	73.9	49.2	90.5	85.4
XGBoost	76.5	47.1	91.5	88.2	75.5	51.3	92.1	86.9
ELM	78.3	48.5	94.6	89.8	78.2	53.0	95.0	90.0
SAE	82.6	50.2	95.2	91.5	82.3	53.6	95.8	92.2
CNN	89.4	53.5	96.2	95.2	91.1	55.1	96.9	95.2
HAND	91.4	58.5	98.6	98.0	97.0	62.8	99.6	97.7

表 3 不同条件下 HAND 方法的性能比较

方法	训练集-验证集-测试集比例 6:2:2				训练集-验证集-测试集比例 8:1:1			
	AUC	F1	MAP@100	MAP@200	AUC	F1	MAP@100	MAP@200
HAND/wo-CA/wo-SA	89.5	53.7	96.4	95.3	91.1	55.4	96.8	95.0
HAND/wo-CA	89.6	56.3	97.6	97.1	95.7	59.5	98.2	96.2
HAND/wo-SA	90.5	56.8	98.0	97.3	96.2	61.3	98.8	96.8
HAND/wo-SL	91.2	58.2	98.5	97.9	96.8	62.6	99.5	97.5
<b>HAND</b>	<b>91.4</b>	<b>58.5</b>	<b>98.6</b>	<b>98.0</b>	<b>97.0</b>	<b>62.8</b>	<b>99.6</b>	<b>97.7</b>

过程中选择使用 0.99 作为参数  $\tau$  的最优取值。

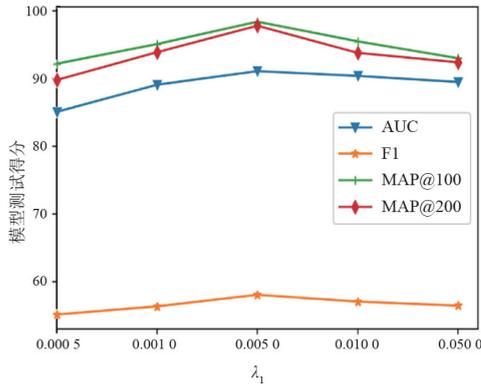


图 3 不同的参数  $\lambda_1$  取值情况下的模型性能

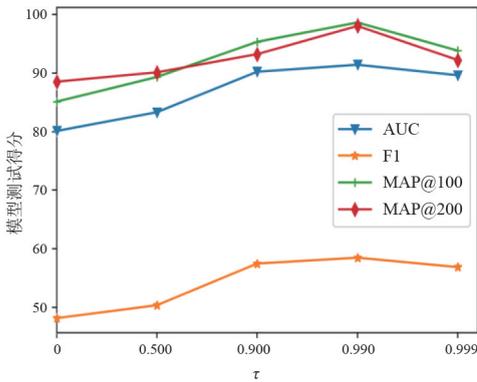


图 4 不同的参数  $\tau$  取值情况下的模型性能

## 4 结 论

窃电行为是当前公共用电安全的一种严重威胁,并且造成巨额经济损失。上面提出了一种基于深度混合注意力网络的窃电检测方法 HAND,将通道注意力和自相关注意力机制相结合,在不同层次和空间范围内对关键信息进行加权和选择,以捕捉数据中的时间依赖性和周期性等复杂特征,并利用自监督方法来学习注意力参数,从而提取出更具表达力和判别力的特征表示。通过在中国国家电网数据集上进行实验分析,并和多种其他窃电检测方法进行对比,验证了所提方法的优越性。由于用电行为数据的收集与标注成本非常高,下一步工作将继续探索在小规模数据集或无标注情况下的窃电检测方法。

### 参考文献

[1] ZHENG Zibin, YANG Yatao, NIU Xiangdong, 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.

[2] NAWAZ Asif, ALI Tariq, MUSTAFA Ghulam, et al. A novel technique for detecting electricity theft in secure

smart grids using CNN and XG-boost [J]. Intelligent Systems with Applications, 2023, 217: 200168.

- [3] 沈嘉怡. AMI 环境下基于深度学习的异常用电监测方法[J]. 自动化与仪器仪表, 2022(5): 112–116.
- [4] 张昕, 孙莉, 许高俊. 基于深度森林算法的异常用电行为检测方法[J]. 电子设计工程, 2022, 30(19): 115–119.
- [5] 王云静, 肖克宇, 曲正伟, 等. 基于用电量曲线和深度学习的非技术性损失检测与识别[J]. 电测与仪表: 1–11 [2023-06-28]. <http://kns.cnki.net/kcms/detail/23.1202.TH.20230213.1641.004.html>.
- [6] NAGI J, YAP K S, TIONG S K, et al. Nontechnical loss detection for metered customers in power utility using support vector machines[J]. IEEE Transactions on Power Delivery, 2010, 25(2): 1162–1171.
- [7] NIZAR A H, DONG Z Y, WANG Y. Power utility non-technical loss analysis with extreme learning machine method[J]. IEEE Transactions on Power Systems, 2008, 23(3): 946–955.
- [8] 吴林峰, 安大炜, 翁亚利, 等. 基于决策树的远程窃电行为识别系统设计[J]. 自动化应用, 2022(10): 15–17.
- [9] 吴蕊, 张安勤, 田秀霞, 等. 基于改进 K-means 的电力数据异常检测算法[J]. 华东师范大学学报(自然科学版), 2020, (4): 79–87.
- [10] ISMAIL M, SHAABAN M F, NAIDU M, et al. Deep learning detection of electricity theft cyber-attacks in renewable distributed generation[J]. IEEE Transactions on Smart Grid, 2020, 11(4): 3428–3437.
- [11] CHATTERJEE S, ARCHANA V, SURESH K, et al. Detection of non-technical losses using advanced metering infrastructure and deep recurrent neural networks[C]// 2017 IEEE International Conference on Environment and Electrical Engineering and 2017 IEEE Industrial and Commercial Power Systems Europe, IEEE, 2017: 1–12.
- [12] HUANG Yifan, XU Qifeng. Electricity theft detection based on stacked sparse denoising autoencoder[J]. International Journal of Electrical Power & Energy Systems, 2021, 125: 106448.
- [13] GAO A, MEI F, ZHENG J Y, et al. Electricity theft detection based on contrastive learning and non-intrusive load monitoring[J]. IEEE Transactions on Smart Grid, 2023, 14(6): 4565–4580.
- [14] ZHU Lipeng, WEN Weijia, LI Jiayong, et al. Deep active learning-enabled cost-effective electricity theft detection in smart grids[J]. IEEE Transactions on Industrial Informatics, 2024, 20(1): 256–268.
- [15] REN Y F, LIU J H, ZHANG H G, et al. TBDA-net: A task-based bias domain adaptation network under industrial small samples[J]. IEEE Transactions on Industrial Informatics, 2022, 18(9): 6109–6119.

- [16] LIAO Wenlong, YANG Zhe, BAK-JENSEN Birgitte, et al. Simple data augmentation tricks for boosting performance on electricity theft detection tasks [J]. IEEE Transactions on Industry Applications, 2023, 59(4):4846-4858.
- [17] FINARDI P, CAMPIOTTI I, PLENSACK G, et al. Electricity theft detection with self-attention[J].https://doi.org/10.48550/arXiv.2002.06219.
- [18] ZHU Yuying, ZHANG Yang, LIU Lingbo, et al. Hybrid-order representation learning for electricity theft detection[J]. IEEE Transactions on Industrial Informatics, 2023, 19(2):1248-1259.
- [19] 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.
- [20] 万磊, 江锐, 黄文杰, 等. 四阶段端到端的用户异常用电模式检测网络[J]. 中南民族大学学报(自然科学版), 2023, 42(1):82-87.

#### 作者简介:

- 彭 军(1969), 男, 高级工程师, 研究方向为营销电能计量;
- 李琪林(1973), 男, 正高级工程师, 研究方向为电力大数据与人工智能;
- 周 尧(1990), 男, 副研究员, 研究方向为人工智能;
- 袁 钟(1991), 男, 特聘副研究员, 研究方向为异常检测及其应用;
- 彭德中(1975), 男, 教授, 研究方向为人工智能;
- 刘益志(1994), 男, 工程师, 研究方向为大数据分析。

(收稿日期:2023-08-23)

(上接第 38 页)

相变换系统输出三相电压不平衡问题, 推导了单/三相变换系统在采用不同两相/三相变压器时的平衡变换条件, 并分析了变压器绕组误差、移相电压输出误差及网侧电压波动对系统输出电压的影响。然后, 针对由移相电压输出误差引起的三相不平衡问题, 提出了一种基于参考电压重构的误差补偿控制策略。仿真结果表明, 所提误差补偿策略能对输出移相电压进行补偿, 从而有效降低系统输出电压不平衡度。

#### 参考文献

- [1] 尤志鹏. 文蒙铁路引入蒙自铁路地区方案研究[J]. 交通与运输, 2022, 38(2):52-56.
- [2] 佚名. 国家电网扶贫成绩单[J]. 国家电网, 2021(3):66-67.
- [3] ZHU Y X, ZHUO F, SHI H T. Power management strategy research for a photovoltaic-hybrid energy storage system[C]. 2013 IEEE ECCE Asia Downunder, 2013:842-848.
- [4] 傅丽. 国外农村典型供电模式及建设运行维护经验[J]. 电力与电工, 2013, 33(4):80-82.
- [5] 尹刚志. 农网台区电能质量综合治理技术研究[J]. 电工技术, 2018(21):118-121.
- [6] 郭爱平. 用于牵引变电所自用电系统的单相-三相变换器研究[D]. 成都:西南交通大学, 2017.
- [7] 庄岩. 铁路单-三相供电系统设计[D]. 成都:西南交通大学, 2011.
- [8] 詹广振. 牵引变电所 27.5kV 所用电系统谐波抑制技术研究[J]. 电气化铁道, 2019, 30(5):46-50.
- [9] 佚名. 增量配电业务新政出台, 鼓励可再生能源就近消纳[J]. 节能与环保, 2018(4):34.
- [10] 王淑娟, 景芳毅. 从度电成本分析光伏平价的路径[J]. 太阳能, 2016(8):9-16.
- [11] KHOSRAVI F, AZLI A N, KAYKHOSRAVI A. Design of a reduced component count single-phase to three-phase quasi-z-source converter[J]. IET Power Electronics, 2014, 7(3):489-495.
- [12] ALMEIDA Antonio D D, ROCHA Nady, FABRICID Edgard L L, et al. Singlephase to three-phase ac-dc-ac converter based on cascaded transformers rectifier and open-end winding induction motor[C]. 2019 IEEE 15th Brazilian Power Electronics Conference and 5th IEEE Southern Power Electronics Conference (COBEP/SPEC). IEEE, 2019:1-6.
- [13] 朱永强, 贾利虎, 谢文超, 等. 一种用于单相/三相变换的新型电力电子变换技术[J]. 电工技术学报, 2018, 33(7):1433-1439.
- [14] 康鹏, 郭伟, 黄伟钢, 等. 区域电网电能质量问题及治理关键技术综述[J]. 电测与仪表, 2020, 57(24):1-12.
- [15] 杨明, 鲍靖雯, 高龙将, 等. 基于参考电流型光伏发电系统变功率输出控制策略[J]. 电力系统保护与控制, 2019, 47(20):104-111.
- [16] PILLAI D S, RAM J P, CHIAS A M Y M, et al. An accurate, shade detection-based hybrid maximum power point tracking approach for PV systems [J]. IEEE Transactions on Power Electronics, 2020, 35(6):6594-6608.

#### 作者简介:

- 李蓉蓉(1994), 女, 硕士, 工程师, 研究方向为电力储能系统的经济性分析;
- 左 为(1989), 女, 工程师, 研究方向为营销市场化管理技术;
- 冉念洁(1994), 女, 硕士, 从事电力系统提质增效工作;
- 周 苏(1995), 女, 硕士, 从事电力营销系统分析工作;
- 王心仪(1997), 女, 硕士, 研究方向为电力系统单相三相变流器控制技术。

(收稿日期:2024-01-08)