

DOI: 10.19783/j.cnki.pspc.240259

基于变分自编码器的多源数据融合窃电检测方法

蔡梓文¹, 赵云¹, 陆煜铎¹, 顾莲墙¹, 陈康², 高云鹏²

(1. 南方电网科学研究院有限责任公司, 广东 广州 510530; 2. 湖南大学电气与信息工程学院, 湖南 长沙 410082)

摘要: 针对当前窃电检测仅使用单一用电负荷难以捕捉复杂窃电特征, 导致窃电检测发生误判, 存在误检率高和准确率低下等问题, 提出一种融合用电负荷、环境温度、时间以及对应台区相位线损的新型窃电检测方法。首先构建多维度特征提取变分自编码器(variational autoencoder for multi-dimensional feature extraction, MF-VAE)来提取用户用电行为的多维度特征。然后, 基于注意力时序卷积网络(attention temporal convolutional networks, ATCN)建立判别模型, 再通过膨胀卷积和因果卷积获取多维度窃电行为特征的时序关系。同时, 引入卷积注意力模块分配各维度特征的注意力权重, 以提高模型的表现和泛化能力。最后采用 Softmax 分类器完成对多源数据中潜在窃电行为的准确识别。实验结果表明, 用该方法提取的窃电行为特征更加丰富和多元化, 能够有效降低窃电检测误检率并提高窃电行为判别准确率。

关键词: 窃电行为判别; 多源数据融合; 改进时域卷积网络; 变分自编码器; 注意力机制

A multi-source data fusion electricity theft detection method based on a variational autoencoder

CAI Ziwen¹, ZHAO Yun¹, LU Yuxin¹, GU Lianqiang¹, CHEN Kang², GAO Yunpeng²

(1. Electric Power Research Institute, CSG, Guangzhou 510530, China; 2. College of Electrical and Information Engineering, Hunan University, Changsha 410082, China)

Abstract: Traditional electricity theft detection methods relying solely on single power consumption loads and struggle to capture complex theft patterns, resulting in high false detection rate and low accuracy. Thus this paper proposes a new electric theft detection method that integrates electric load, ambient temperature, time and corresponding phase line loss of the station area. First, a multi-dimensional feature extraction variational autoencoder (MF-VAE) is constructed to extract the multi-dimensional characteristics of the user's electricity consumption behavior. Then, an attention temporal convolutional network (ATCN) is employed to establish a discriminator model, where expansion convolution and causal convolution are used to obtain the temporal relationships of multi-dimensional electric theft features. Meanwhile, a convolutional attention module is introduced to assign the attention weight of each dimension feature to improve the performance and generalizability of the model. Finally, a Softmax classifier is used to accurately identify potential power theft behaviors in multi-source data. Experimental results show that the characteristics of electric theft behaviors extracted by the proposed method are more abundant and diversified, which can effectively reduce false detection rates and improve the accuracy of electric theft behavior identification.

This work is supported by the Open Fund of Guangdong Provincial Key Laboratory of Intelligent Measurement and Advanced Metering of Power Grid (No. GPKLIMAMPG-2022-KF-04).

Key words: electricity theft behavior identification; multi-source data fusion; improved time-domain convolutional network; variational autoencoder; attention mechanism

0 引言

配电过程中的电能损失对电力系统的安全、优

质和经济运行影响巨大。在电力系统中, 电能损失是指最终用户没有支付给电网的电量, 主要分为两种类型: 技术性损失(technical loss, TL)和非技术性损失(non-technical loss, NTL)^[1-2]。技术性损失是能量传输所固有的, 主要包括功率损耗。非技术性损失包括电能表篡改、电能表故障、非法连接、违规

基金项目: 广东省电网智能量测与先进计量企业重点实验室开放基金项目资助(GPKLIMAMPG-2022-KF-04)

计费 and 未付账单, 其中电力用户的窃电行为是导致非技术性损失的重要因素^[3-5]。

随着科学技术的不断发展, 窃电方式变得更加先进、多样和隐秘, 而传统的异常用电检测技术及用电管理模式相对落后, 两者之间的矛盾日益加剧。因此, 如何有效地检测异常用电行为成为迫切需要解决的问题^[6]。在高级量测体系(advanced metering infrastructure, AMI)的支持下, 智能电能表具有监测指标多、上传数据量大等特征^[7], 成为智能电网中必不可少的组成部分, 并能够高频率地采集大量的用电负荷数据^[8-9]。用电异常包括两个维度, 即由计量引起的异常用电量数据和包括窃电行为在内的异常用电行为^[10]。通过信息流和能源流进行融合, 智能电网可利用数据挖掘技术深入分析和挖掘用户负荷数据, 以便检测窃电者的异常用电行为模式。文献[11]充分利用数据中隐含的时序特征, 提出一种基于双向深度循环神经网络的窃电检测方法, 通过采集大量的用电负荷数据, 提高模型的窃电判别准确度和鲁棒性。文献[12]提出一种基于决策树(decision tree, DT)和支持向量机(support vector machine, SVM)的综合自顶向下方案, 能够精确地检测和定位电力传输和配电各个级别的实时窃电。文献[13]基于正常与异常用电用户的用电规律差异, 提出一种最优路径森林(optimal path forest, OPF)聚类算法的无监督窃电检测方法。文献[14]针对小用户级别的窃电, 提出一种基于模糊聚类的异常用电行为识别方法, 并且考虑用户用电数据平均谱半径波动对用户嫌疑的窃电时间区间进行估计。文献[15-16]提出一种基于相对密度分析的用电异常行为检测算法, 由于其无须构建分类平面以及设定类别数目, 具有较强的自适应性。上述技术方法通过对用户的用电负荷进行数据挖掘, 有效提高了窃电检测的精度和效率, 但随着窃电手段的多样化, 仅使用单一的用电负荷难以充分捕捉复杂窃电特征, 从而导致当前窃电检测模型发生误判, 且存在误检率高和准确率低下等问题^[17], 难以满足实际复杂用电环境下高效准确窃电检测的需求。

为此, 本文提出一种基于多维度特征提取变分自编码器的多源数据融合窃电检测方法。首先, 利用用户的用电负荷、用电时间、用电时环境温度以及用户所在台区线损构建多源数据, 环境温度的考虑使得模型更好地适应季节性用电负荷的波动, 时间信息有助于模型理解用电行为的时间模式, 而对应台区相位线损则提供了额外的电能损耗信息。通过这种维度的增加, 模型能够更全面、精确地捕捉用户用电行为的多样性。其次, 构建多维度特征提

取变分自编码器(variational autoencoder for multi-dimensional feature extraction, MF-VAE)来提取多源数据的窃电特征; 建立基于注意力机制的时序卷积神经网络(attention temporal convolutional networks, ATCN)的窃电行为判别模型, 通过膨胀卷积以及因果卷积网络获取不同输入通道特征的时序关系, 引入卷积注意力模块分配各特征的注意力权重, 提高窃电行为判别模型的泛化能力, 并通过电网实测数据验证所提方法的准确性和有效性。

1 多维度关联特征提取

通过对用户负荷数据进行时间和环境温度相关特征提取, 可以更好地反映出时间和环境温度对用户负荷的影响。在深度学习模型中, 特征提取是非常关键的一步。特征提取的目的是将原始数据转换为更高级别、更抽象的特征表示, 以便于后续的学习任务。对于用户用电量数据, 特征提取可以将数据中的无用信息去除, 同时保留数据中对于窃电行为最具有判别性的特征, 从而提高模型的精度和泛化能力。

1.1 变分自编码器

变分自编码器(variational autoencoder, VAE)是一种生成模型, VAE 结合自编码器(autoencoder, AE)和贝叶斯概率模型的思想, 利用神经网络来对数据进行编码和解码, 且能够从编码中提取连续且可解释的潜在特征^[18]。其主要思想是将自编码器中的编码器(Encoder)和解码器(Decoder)分别看作概率模型的推断网络和生成网络。编码器将输入数据转换为潜在变量的概率分布, 而解码器则从潜在变量的分布中生成新的数据样本。VAE 将编码器中的中间层输出视为潜在变量 z 的均值和方差, 通过从一个先验分布中采样来生成潜在变量 z , 然后 z 作为解码器的输入, 从潜在变量的分布中生成新的数据样本。VAE 通过最大化数据样本的边际对数似然证据下界(evidence lower bound, ELBO)来学习潜在变量的分布。ELBO 由对数似然和 KL 散度两部分构成, 其计算式如式(1)所示。

$$\lg p(x) \geq \mathbb{E}_{z \sim q(z|x)} [\lg p(x|z)] - D_{\text{KL}}(q(z|x) \| p(z)) \quad (1)$$

式中: $\lg p(x)$ 是给定观测数据的对数似然; $\mathbb{E}_{z \sim q(z|x)} [\lg p(x|z)]$ 是重构误差项, 表示在近似后验分布 $q(z|x)$ 下, 生成数据 x 的对数似然的期望值, $\lg p(x|z)$ 是数据样本 x 在给定潜在变量 z 的条件下的条件概率密度函数; $D_{\text{KL}}(q(z|x) \| p(z))$ 是编码器生成的近似后验分布 $q(z|x)$ 与先验分布 $p(z)$ 之间的 KL

散度，通过最小化 KL 散度，模型被鼓励生成的潜在变量分布更接近于先验分布，这有助于确保模型学到的潜在变量在整个潜在空间中均匀分布，而不是过于局限于某个特定区域，避免模型可能会学到训练数据的噪声或过度适应训练集的特定模式，导致在未见过的数据上性能下降，发生过拟合现象。

VAE 的训练过程可分为两步：通过编码器将输入数据 x 转换为潜在变量 z 的近似后验分布 $q(z|x)$ ，然后从中采样得到潜在变量 z ；使用解码器从潜在变量 z 的分布中生成新的数据样本，通过最大化 ELBO 来学习潜在变量的分布，使得生成模型更具有普适性，能够适应多样性的数据分布，并且可以更好地应对实际应用中的复杂情况。

1.2 卷积自编码器特征提取

一维卷积变分自编码器 (1D convolutional variational autoencoder, 1D-CVAE) 是一种基于一维卷积神经网络和变分自编码器 (VAE) 的生成模型，主要用于对具有时间序列结构的数据进行建模。本文在 1D-CVAE 模型基础上提出一种新的多维度特征提取变分自编码器 (variational autoencoder for multi-dimensional feature extraction, MF-VAE)。

为使自编码器模型具有提取时间、环境温度相关特征的能力，对模型的任务进行修改：假设用户的用电波形受到时间和环境温度数值与其变化的影响，在原始用电数据重构任务的基础上增加时间、环境温度多维关联特征提取任务，提高模型对用户用电行为的理解和建模能力，使得模型更加准确地识别潜在的窃电行为，从而提高窃电检测系统的可靠性和效果。多维度特征提取变分自编码器模型结构如图 1 所示。

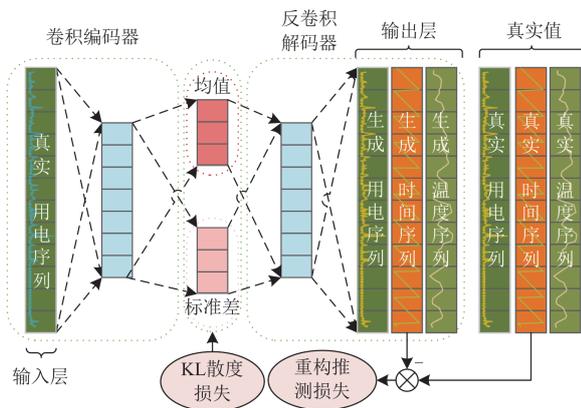


图 1 多维度特征提取变分自编码器模型结构图

Fig. 1 Structure of multi-dimensional feature extraction variational autoencoder model

设输入数据为一维信号 x ，输入信号的长度为 L ，所设计的变分自编码器的目标是将其映射到一个低维潜在变量 z ，然后通过解码器将其重构为输出信号 \hat{x} ，以及通过用电数据推断出的时间数据 \hat{t} 和环境温度数据 \hat{T} ，输出数据的长度均与输入一致，在图 1 中用真实用电序列、生成用电序列、生成时间序列和生成温度序列表示。

一维多维度特征提取变分自编码器的编码器和解码器均由一维卷积层和池化层构建。其中，编码器通过多个一维卷积层和池化层，逐渐将输入信号 x 编码为潜在变量 z ，解码器则通过多个一维转置卷积层和反池化层将潜在变量 z 解码为重构信号 \hat{x} 与推测时间、环境温度信号。在这个过程中，潜在变量连接输入数据和生成数据，是用电序列数据进行抽象和表示特征的关键元素。通过学习这些潜在变量，模型可以更好地理解输入用电序列数据的结构，实现对时间序列和环境温度序列的高效生成和推断。一维多维度特征提取变分自编码器的编码器和解码器的计算式如式(2)所示。

$$z \sim q_\phi(z|x) = N(u_\phi(x), \delta_\phi^2(x)) \quad (2)$$

式中： $q_\phi(z|x)$ 是一个条件概率分布，表示在给定输入数据 x 的情况下，潜在变量 z 的分布； $u_\phi(x)$ 表示 x 通过参数总体为 ϕ 的若干层一维卷积层和池化层编码器后输出的均值； $\delta_\phi^2(x)$ 表示最后输出得到的方差。

$$\begin{cases} \hat{x} \sim p_{\theta_0}(x|z) = N(f_{\theta_0}(z), \sigma^2 \mathbf{I}) \\ \hat{T} \sim p_{\theta_2}(T|z) = N(f_{\theta_2}(z), \sigma^2 \mathbf{I}) \\ \hat{t} \sim p_{\theta_1}(t|z) = N(f_{\theta_1}(z), \sigma^2 \mathbf{I}) \end{cases} \quad (3)$$

式中： \hat{t} 是时间信号； \hat{T} 是温度信号； \mathbf{I} 是单位矩阵； $f_{\theta_0}(z)$ 、 $f_{\theta_1}(z)$ 、 $f_{\theta_2}(z)$ 表示解码器的输出，由一维转置卷积层和反池化层计算得到； σ^2 是输出信号的方差，通常被设置为一个较小的常数； $p_{\theta_0}(x|z)$ 、 $p_{\theta_1}(t|z)$ 、 $p_{\theta_2}(T|z)$ 分别是给定潜在变量 z 后，输入信号 x 、 t 、 T 的条件概率分布，这些分布是均值分别为 $f_{\theta_0}(z)$ 、 $f_{\theta_1}(z)$ 、 $f_{\theta_2}(z)$ ，方差均为 $\sigma^2 \mathbf{I}$ 的多元正态分布。一维多维度特征提取变分自编码器的损失函数由两部分组成：重构误差和 KL 散度误差。重构误差衡量重构信号与输入信号的差异，KL 散度误差则衡量潜在变量 z 与标准正态分布之间的差异。因此，一维多维度特征提取变分自编码器的总体损失函数可以表示为

$$\mathcal{L}(\theta, \phi; x) = \frac{1}{2} \sum_{l=1}^L \underbrace{[(\hat{x}_l - x_l)^2 + (\hat{t}_l - t_l)^2 + (\hat{T}_l - T_l)^2]}_{\textcircled{1}} = \underbrace{D_{\text{KL}}(q_{\phi}(z|x) \| p(z))}_{\textcircled{2}} \quad (4)$$

式中: x_l 、 t_l 、 T_l 分别为真实输入的用电序列、时间序列及温度序列的第 l 个特征值; \hat{x}_l 、 \hat{t}_l 、 \hat{T}_l 分别为经过变分自编码器重构的用电序列、时间序列及温度序列的第 l 个特征值; 第一项①为均方误差, 用于衡量输入用电波形与重构用电波形之间的重构误差, 以及真实环境温度时间波形与推测的环境温度时间波形之间的推测误差之和; 由中心极限定理和计算求解的便利性考虑, 将 $p(z)$ 设定为正态分布。第二项②为 KL 散度, 用于测量潜在变量近似后验分布 $q(z|x)$ 和先验分布 $p(z)$ 之间的距离。优化模型的过程是通过利用模型参数对计算损失函数的

梯度来迭代调整模型参数, 从而获取最小化的损失函数值。

MF-VAE 通过对原始用电序列的重构, 使得模型可以有效学习在潜在空间表示关键用电特征的能力, 进而确保解码器生成的重构信号能够尽可能地保留原始用电数据的结构和特性。同时, 有助于仅利用原始用电数据生成时间数据和环境温度数据, 解决了当前窃电检测数据单一的问题, 为后续多源数据融合的窃电检测奠定基础, 更加有利于提高窃电检测准确性和降低误检率。

2 改进的时域卷积网络

2.1 时域卷积

TCN 的卷积层结合因果卷积和膨胀卷积, 膨胀因果卷积模型如图 2 所示。输入模型的信号是用电量的时间序列信号以及由用电量生成的用户时间、环境温度相关特征。

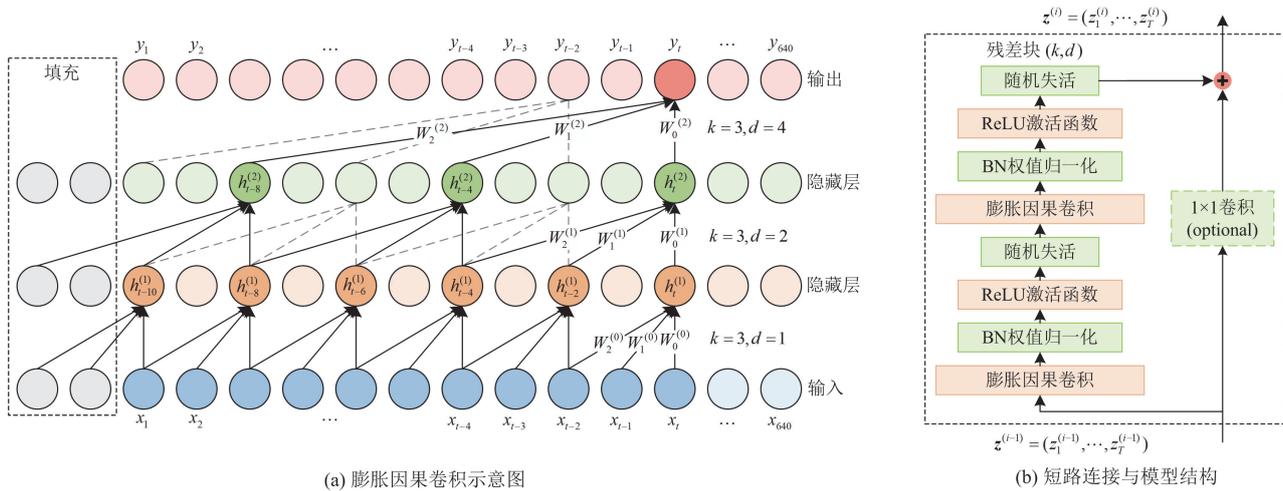


图 2 膨胀因果卷积模型示意图

Fig. 2 Schematic diagram of the dilation causal convolution model

因果卷积操作通过卷积权重的向前连接的方式确保时刻的输出仅取决于过去时间的输入, 以避免未来数据信息的泄漏; 膨胀卷积操作在标准卷积核中插入了间隔, 记间隔数据点数为膨胀系数 d , 卷积核的大小为 K , 可以在不增加模型参数的情况下为模型提供更大的感受野, 在对时序信号的卷积操作中, 感受野用于表示可以使用的历史数据范围。

模型的输入信号长度为 l , 数据维度(通道数)为 k , 其中一个通道的数据表示为 $x_c = [x_1, x_2, \dots, x_l]$, $c \in \{1, 2, \dots, k\}$, 记 $h^{(i)}$ 和 $W^{(i)}$ 分别为第 i 个隐藏层的输入数据和时域卷积核, $Con_{\text{dc}}^{(i)}(t)$ 表示第 i 个隐藏

层 t 时刻的输出 y_t 对应的时域卷积运算, 其计算式可以表示为

$$Con_{\text{dc}}^{(i)}(t) = (h^{(i)} * W^{(i)})(t) = \sum_{j=0}^{K-1} W_j^{(i)} \cdot h_{t-j \cdot d^{(i)}}^{(i)} \quad (5)$$

式中: “*” 为卷积操作运算符; K 为卷积核的大小; $d^{(i)}$ 为第 i 层卷积操作设定的卷积膨胀系数, 于是感受野的大小可以使用 $(K-1) \times d^{(i+1)}$ 计算得到。

2.2 短路连接与残差块

TCN 使用短路连接构造的时序卷积块来避免模型在训练过程中的梯度消失和梯度爆炸问题^[19]。残差块结构如图 2(b)所示, 残差是指预测值和观测值之间的差距, 使用短路连接的方式连接多层膨胀

因果卷积的输入和输出，使模型在训练中自动选择该卷积层的接入比例，从而避免因模型深度过深而训练困难的问题。短路连接将所连接的模块输入直接连向输出，使得模型可以在训练过程中通过调整模块的权重系数，自适应地选择是否使用短路连接中的模型，短路连接的原理可表示为

$$z^{(i+1)} = \sigma(F(z^{(i)}) + z^{(i)}) \quad (6)$$

式中： $z^{(i+1)}$ 为残差块输出； $z^{(i)}$ 为第*i*个残差块的输入； $F(z^{(i)})$ 为残差块中多层膨胀因果卷积变换的结果； σ 为sigmoid函数。

2.3 引入注意力机制 TCN

为利用多源数据实现窃电行为判别任务，模型需要具有时序数据的特征抽象能力以及对多源数据特征的分析能力。本文构建一种由时间卷积网络(temporal convolutional networks, TCN)作为特征提取器、卷积块注意力模块(convolutional block attention modul, CBAM)和多层感知器(multi-layer perceptron, MLP)特征分类器组成的注意力机制时间卷积网络(ATCN)结构，如图3所示。在整个模型中，TCN用于提取输入多源数据时序特征，其通过卷积操作捕捉长期时序依赖，为模型提供了丰富的时序信息。CBAM作为进一步的处理步骤，通过引入通道和空间注意力机制，对TCN提取的特征进行巧妙的调整，使模型能够更专注地关注窃电行为判别任务中的重要特征。最后，Softmax分类器负责将经过TCN和CBAM处理的时序特征映射到各类别的概率分布上，完成最终的分类预测。

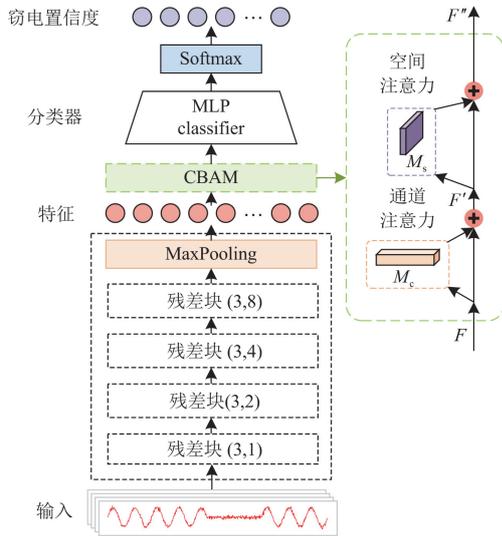


图3 窃电行为判别模型结构

Fig. 3 Structure of discrimination model for electricity theft behavior

CBAM通过通道注意力和空间注意力机制，有效地提高模型对重要用电信息的关注度，同时减弱

了对无关信息和噪声的敏感性，提高了窃电检测模型在实际工程应用中的可靠性和实用性。通道注意力模块(channel attention module, CAM)是将TCN提取的用电特征在空间维度上进行压缩，得到一维矢量后再进行操作，用于对每个用电特征通道进行加权，以提高具有关键用电信息的通道权重，降低不重要通道的权重。CAM使用全局最大池化和全局平均池化AvgPool(·)将输入特征表示映射压缩为通道维度上的两组不同的通道权重，然后将这些特征输入到具有一个隐藏层的全连接网络MLP中，对各个元素求和并输出特征向量，使用sigmoid激活函数生成通道注意力权重^[23]。通道注意力权重为

$$M_c(F) = \sigma(G_1(G_2(F)) + G_1(G_3(F))) \quad (7)$$

式中： $M_c(F)$ 为通道注意力模块生成的特征图； F 为前置模型提取得到的特征图； G_1 为全连接网络MLP； G_2 为全局平均池化AvgPool(·)； G_3 为最大池化层Maxpool。

在CAM之后，空间注意力模块(spatial attention module, SAM)则用于对用电信息特征的不同位置进行加权，以突出包含重要用电信息的区域。同时，起到补充通道注意力模块提供的通道权重、查找关键用电信息位置的作用。

将CAM的输出作为SAM的输入，通过全局最大池化和全局平均池化操作得到两个特征图，两张特征图根据通道进行拼接，并通过核大小为7的一维卷积运算操作进行权重提取，利用sigmoid激活函数生成空间注意力图。空间注意力权重为

$$M_{cs}(F_1) = G_5(M_c(F_1) \oplus M_s(F_1)) \quad (8)$$

式中： $M_{cs}(F_1)$ 为CBAM特征过滤器生成的特征图； F_1 为通道注意力加权之后的特征值；“ \oplus ”为逐元素相加操作； $M_c(F_1)$ 为通道注意力加权之后的特征值经过通道注意力模块生成的特征图； $M_s(F_1)$ 为空间注意力模块特征图。

CBAM根据分配不同位置的注意力不同，实现减少模型的参数大小与计算量以及突出重要特征的作用。最后将CBAM构建的特征连接到全连接层，通过Softmax函数转换为对窃电行为各类别的置信度，概率最大的类别即为模型的预测结果，表示输入用电序列的真实标签。

3 数据集构建及实验结果分析

3.1 数据集构建

本文数据来源于湖南省某3个拓扑关系明确的相邻低压台区，包含300个用户，由用电信息采集系统获取，采集频率为30 min/次，时间范围为2022年4月9日—2022年7月9日，用电信息包括用电

功率、时间和温度。由于真实窃电数据难以获取, 本文采用数学模型篡改的方式构造窃电样本, 篡改计算式为

$$\begin{cases} h_1(x_t) = \beta x_t, \beta = \text{random}(0.1, 0.8) \\ h_2(x_t) = \min(x_t, \gamma_1), \gamma_1 = \text{random}(0, 1) \times x_{t, \max} \\ h_3(x_t) = \max\{x_t - \gamma_2, 0\}, \gamma_2 = \text{random}(0.1, 0.8) \times x_{t, \max} \\ h_4(x_t) = 0 \\ h_5(x_t) = \beta_t x_t, \beta_t = \text{random}(0.1, 0.8) \\ h_6(x_t) = x_{t_0} \\ h_7(x_t) = x_{-t} \end{cases} \quad (9)$$

式中: x_t 表示窃电用户在 t 时刻的负荷数据; $x_{t, \max}$ 表示用电负荷最大值; 窃电构造函数 $h_1 - h_7$ 总结各种窃电手段对应的计量数据篡改规律; h_1 表示按固定比例减小电表计量电量, 如更换互感器、分压分流等窃电手段, 其中 β 为电能减小比例; h_2 表示拦截超过阈值报告窃电, 其中 γ_1 为人为设定的阈值; h_3 表示固定值电能减少, 如部分绕越窃电方式, 其中 γ_2 表示绕越负荷的比例; h_4 表示电量为 0, 代表电表开路、断开电压表连接片、完全绕越等窃电手段; h_5 表示电能减小比例随时间变化的窃电手段, 如电压测量回路接触不良、相线错接、改变负荷性质、强磁窃电等窃电手段, 其中 β_t 为随时间变化的削减比例; h_6 表示使用采样初始值变化的负荷, 如扩大采样间隔窃电方式, 其中 x_{t_0} 表示窃电行为开始时刻的负荷计量值; h_7 表示负荷数据记录时间错位, 如颠倒用电时序降低电费成本的窃电手段, 其中 x_{-t} 表示颠倒时序后的用电负荷序列。

将原始台区用电功率、时间、温度数据以 15 天为检测窗口构建湖南省电网数据集, 划分训练集: 验证集: 测试集为 6:2:2。其信息如表 1 所示。

表 1 湖南省电网数据集信息

数据集参数名称	参数值
样本个数	1800
时间跨度	2022 年 4 月 9 日—2022 年 7 月 9 日
训练: 验证: 测试	6:2:2
样本内容	用电功率、时间、温度
样本维度	720×3×1

窃电样本生成的输入数据是正常用户的用电数据, 所生成的样本为该用户在使用特定窃电手段模拟后生成的窃电样本, 由于用户窃电行为存在时间各不相同, 引入窃电时间比例 u 表示用户窃电时

间占所观察时间的比例。为表示不同窃电手段对用户用电的不同影响, 选取一个用户的用电负荷, 在固定时间进行各种窃电行为模拟, 各种窃电行为对用户负荷数据的篡改如图 4 所示。

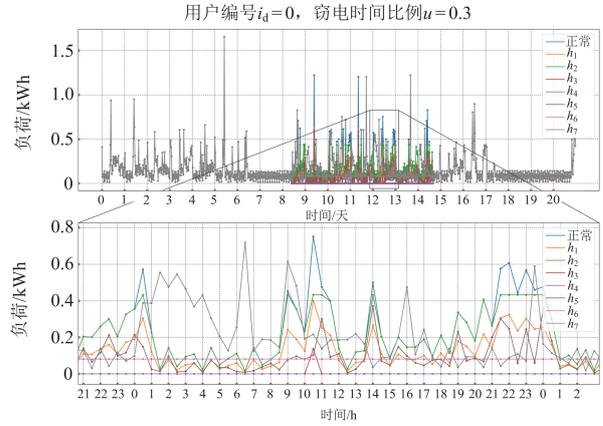


图 4 篡改后负荷变化曲线

Fig. 4 Load variation curve after tampering

3.2 特征提取模型验证

自编码器模型通过层与层的连接, 实现对原有输入进行维度的压缩以及重构操作。

其中, 瓶颈层是模型编码器的末端输出层以及解码器的输入层。定义 l_d 表示瓶颈层的维度数, 如果 l_d 过高, 可能会导致自编码器学习的规则过于复杂, 从而过拟合训练数据。反之, 如果 l_d 过低, 则可能会导致自编码器无法很好地保留输入数据的主要特征, 从而导致欠拟合。因此, 选择适当的维度数 l_d 非常重要。模型的其他参数如层数、卷积核大小、步长以及通道数等, 根据所输入数据的长度和通道数而定。实验确定 MF-VAE 模型结构及训练参数如表 2 所示。

表 2 MF-VAE 结构及训练参数

结构	参数
编码器	层属性×数量: 一维卷积×5 卷积层通道数: [32,64,128,256,512] 卷积核大小, 步长, 填充: (5,2,1) 激活函数: LeakyReLU
瓶颈层	维度: 1024
解码器	层属性×数量: 一维转置卷积×5 转置卷积层通道数: [256,128,64,32,32] 卷积核大小, 步长, 填充: (5,2,1) 激活函数: LeakyReLU
输出层	层属性: 一维卷积 输出通道数: 3 卷积核大小, 步长, 填充: (3,1,1) 激活函数: 无
训练参数	迭代次数: 200, 优化器: Adam 学习率: 0.001

训练集、验证集的损失值随训练轮次变化曲线如图 5 所示。训练集损失函数曲线与验证集损失函数曲线十分接近，表明本文建立的窃电检测模型没有出现拟合和欠拟合现象，同时说明瓶颈层的维度数 l_d 选择合适。

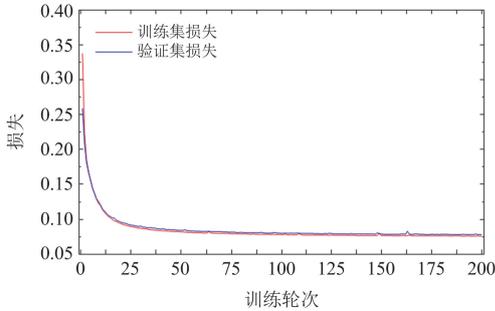


图 5 训练集及验证集损失函数曲线

Fig. 5 Training set and verification set loss function curve

MF-VAE 模型的效果由测试集样本的均方根误差来衡量，图 6 展示了模型对测试集用户中 id 编号为 7 的用户用电量重构效果。

图 6 中红色虚线为用户 7 的真实用电波形，黑色实线为模型对真实用电波形的重构结果。从图 6 中左侧放大区域可知，真实与生成的功率波形在各个时间点上的幅值基本相同，相对误差较小，说明模型对输入用电波形的特征提取基本保留了用户的用电量剧烈变化信息；由图 6 中右侧放大区域可知，真实与生成的功率波形在用户用电量较低且振荡时有较大的相对误差，说明模型在特征提取时去除了用户的低用电噪声。

对于电力用户的窃电检测来说，大功率的用电规律是模型需要关注的重要特征，而小功率持续用电的具体幅值波动是模型较为不需要的信息。模型

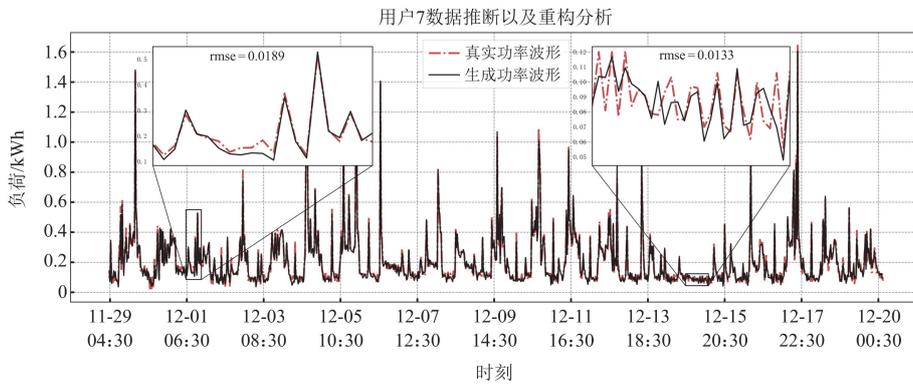


图 6 用户功率波形重构效果图

Fig. 6 User power waveform reconstruction effect

基于损失函数通过数据值而不是变化率对用电信息所有的点进行计算，从而实现有效特征的提取和噪声的滤除，所得特征相比原始波形对于窃电行为判别具有更大的信息密度。

用电时间波形预测效果图如图 7 所示。图 7 中红色虚线为真实的时间信息，以一天的 00:00 为起始点，一天的 23:30 为终止点，间隔为 0.5 h，对一天的时间编码，所得波形是以一天为周期的三角波。图 7 中黑色实线为模型根据用户用电功率波形推断出的时间波形，推断的难点在于用电起始点的推测以及周期性的维持。由图 7 可知，图中真实与生成波形的起始点与结束点基本重合，表明模型具有根据用户用电波形推断用电时间的能力。而在 12 月 7 日—12 月 11 日模型推断出的时间波形与真实波形在周期和幅值上相差较大，表明用户 7 在这段时间内用电的周期性较弱。由此可知，模型对功率波形具有一定的时间相关特征的提取、抽象能力。

并且，用户的用电行为与时间有较强的关联性，时间波形可以辅助判别窃电行为。

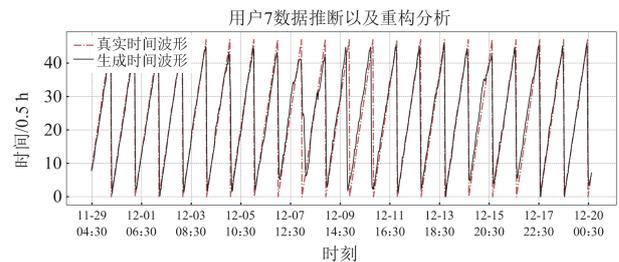


图 7 用电时间波形预测效果图

Fig. 7 Electricity time waveform prediction effect

用电对应环境温度波形预测效果如图 8 所示，其中红色虚线表示用户用电时刻对应的真实环境温度波形，黑色实线表示模型根据功率波形推断出的环境温度波形。由图 8 可知，模型对于环境温度推断较为模糊，因为环境温度变化波形相较于时间波

形更为复杂, 且对于不同用户用电的影响各异, 使用功率波形对环境温度进行重构是相对困难的任务。但图 8 中真实和生成温度波形的变化趋势基本一致, 说明本文所提模型在训练后能够对环境温度的变化趋势进行较为准确的估计, 且对功率波形具有一定的环境温度相关特征的提取、抽象能力。

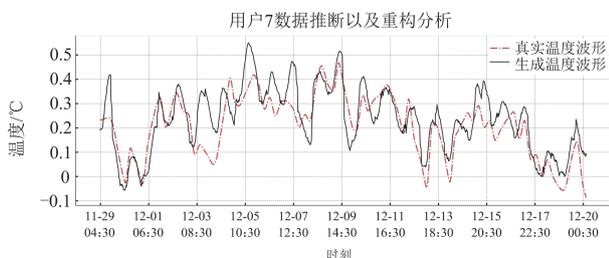


图 8 对应环境温度波形预测效果图

Fig. 8 Waveform prediction effect diagram corresponding to environmental temperature

3.3 窃电检测模型验证

为验证所构建模型的性能, 首先对台区用户数以及窃电用户数进行模拟。台区相位的线损可以为用户是否存在窃电行为提供参考。单个台区相位中存在的窃电用户越多, 对台区中用户的窃电行为判别任务也就越困难。假设单个相位出线连接 30 到 100 个用户, 采用台区相位窃电概率 p 来模拟窃电情况, 图 9、图 10 展示了 p 分别为 0.01 和 0.05 时台区用户以及窃电用户分布, 其中红色柱形的高度表示正常用户的数量, 蓝色柱形的高度表示窃电用户的数量。

由图 9、图 10 可知, 台区相位窃电概率 p 直接影响了相位中窃电用户与正常用户的比例。选择台区相位窃电概率 p 为 0.02, 定义窃电用户的窃电时间占整段观测窗口时间的比例为 u , 选择 u 为 0.3 对用户窃电行为进行模拟, 利用所构建的窃电行为判别模型基于多源数据对图 9、图 10 中区域进行窃

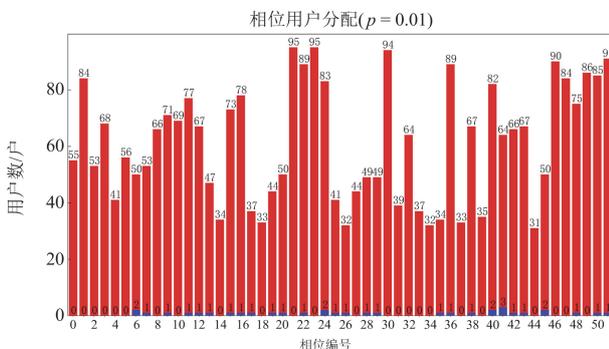


图 9 $p = 0.01$ 时台区用户分布

Fig. 9 Distribution of users in station area when $p = 0.01$

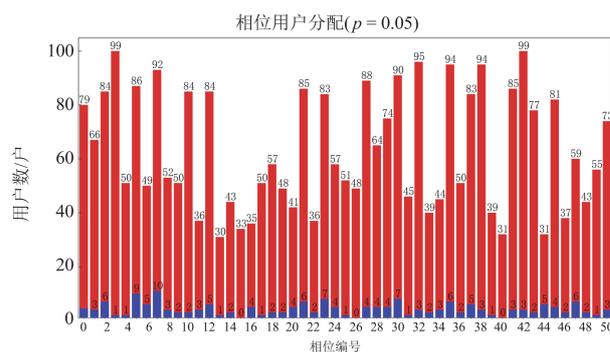


图 10 $p = 0.05$ 时台区用户分布

Fig. 10 Distribution of users in station area when $p = 0.05$

电行为的检测, 窃电检测结果如表 3 所示, 表中 FDI 为虚假数据注入的类型。

表 3 虚拟台区组窃电检测结果

Table 3 Electricity theft detection results of virtual station group

FDI	ACC/%	PRE/%	REC/%	FPR/%	TPR/%	F1 分数
正常	99.48	99.28	99.61	22.92	99.57	0.9944
1	76.84	82.35	63.64	0.06	63.64	0.7179
2	75.68	67.86	41.30	0.13	41.30	0.5135
3	78.99	89.74	70.00	0.04	70.00	0.7865
4	96.15	64.86	96.00	0.17	96.00	0.7742
5	88.66	86.11	83.78	0.05	86.48	0.8493
6	78.20	68.00	68.00	0.11	68.00	0.6800
7	94.78	100.00	91.42	0.00	94.29	0.9522
宏平均	86.10	82.28	76.72	2.93	77.41	0.7839

由表 3 可知, ATCN 模型在台区相位窃电概率为 0.02、窃电时间比例为 0.3 的虚拟台区中, 窃电行为的检测准确率(accuracy, ACC)为 86.10%, 基于数据集的精确率(precision, PRE)为 82.28%, 召回率(recal, REC)为 76.72%, 真正率(true positive rate, TPR)为 77.41%, 假正率(false positive rate, FPR)为 2.93%, 即正常用户被误判概率为 2.93%时, 可检出 77.41%的窃电用户, 真实窃电的用户被判断为窃电的概率为 76.72%, 判别为窃电的用户中有 82.28%的用户存在窃电行为。

为了更直观地观察各类别数据的误判情况, 利用混淆矩阵分析窃电行为判别模型对各个类别样本的分类情况, 判别结果的混淆矩阵如图 11 所示。由图 11 可知, 本文提出的方法在 $p = 0.02$ 、 $u = 0.3$ 情况下, 由于 h_2 、 h_5 和 h_6 在电能篡改规律上的相似性, 可能会导致一定程度的混淆。对于 h_1 窃电行为的检测效果较差, 但能够对 h_3 、 h_4 、 h_7 这 3 种窃电行为进行稳定准确的检测。

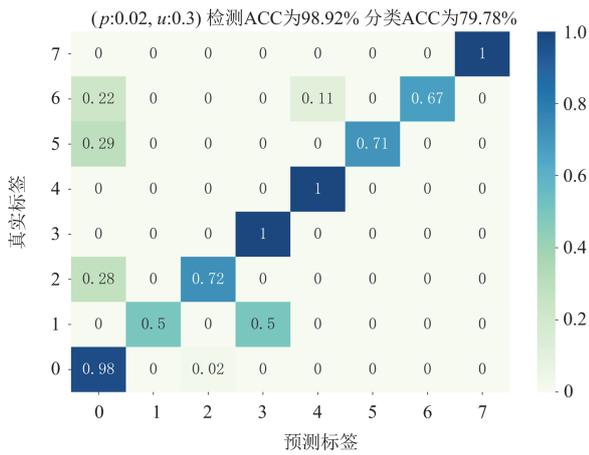


图 11 模拟台区窃电检测混淆矩阵

Fig. 11 Confusion matrix of electricity theft detection in analog station area

3.4 窃电检测模型灵敏度分析

为验证对现有智能电能表结构下的负荷数据在用户负荷的时间相关特征维度、环境温度相关特征维度，以及用户所在台区线损维度的数据维度扩充方法对模型判别效果的影响，设计用户负荷数据 E 、用户负荷的时间相关特征数据 t 、用户负荷的环境温度相关数据 T 和用户所在台区线损数据 L 共 4 个维度数据分别训练模型，通过准确率(ACC)、异常分类准确率(fraud accuracy, FACC)、精确率(PRE)、真正率(TPR)、假正率(FPR)、F1 分数(F1-score, F1)、受试者工作特征曲线下面积(area under the ROC curve,

AUC)评价指标对不同数据模型进行窃电行为判别效果分析。所构建的 ATCN 模型特征提取器的输出层参数设定为 48，即对于单个样本其输出的 48 维向量代表样本潜在的窃电行为信息，不同输入维度的窃电检测结果如表 4 所示。

表 4 不同输入维度的窃电检测结果

Table 4 Electricity theft detection results with different input dimensions

输入数据	ACC	FACC	TPR	FPR	AUC
$[E]$	98.07	34.62	56.92	2.55	90.57
$[E, t]$	98.35	41.54	63.85	1.25	92.33
$[E, t, T]$	98.57	56.92	61.54	0.77	93.69
$[E, t, T, L]$	98.94	70.00	82.31	0.61	96.81

由表 4 可知，不同窃电行为在不同的数据维度上的特征明显不同，利用多源数据可为模型提供更多的窃电行为判别依据，使用用电时间特征 t 、用电环境温度特征 T 、所属台区线损数据 L 作为对用电数据 E 的维度补充，可以获得更好的窃电行为检测准确率以及更低的误检率。且从 ACC、FACC、PRE、TPR、FPR、F1、AUC 指标数据可知，数据维度越丰富，模型窃电行为判别的越好。

为更直观地体现本文所提算法的特征提取能力，t-SNE 特征可视化分析的特征提取效果以及判别结果如图 12 所示。

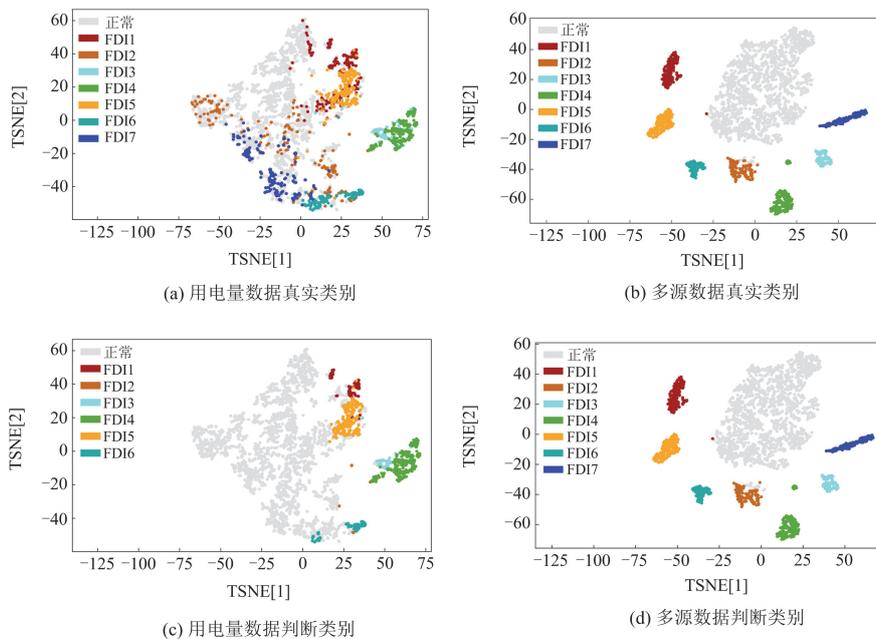


图 12 特征提取效果与判别结果图

Fig. 12 Feature extraction effect and discrimination results

由图 12(a)、图 12(b)可知, 同类别数据的聚集以及不同类别数据的离散程度相较于只使用用电数据, 使用从多源数据中提取用户的窃电类型特征更具窃电行为区分度。纵向比较图 12(a)、图 12(c)和图 12(b)、图 12(d)可知, 使用用电数据的样本判别结果与真实类别有较大差距, 而使用多源数据的样本判别结果和真实类别较为接近, 表明模型使用多源数据可以获得更好的分类性能。

3.5 窃电用户比例影响分析

对于不同区域, 窃电用户比例往往不同, 因此在原有数据集基础上, 构建多组具有不同窃电用户比例的数据集进行实验, 检验窃电检测模型在不同窃电用户比例情况下的性能。窃电检测性能随窃电用户比例变化对比和结果分别如图 13 和表 5 所示。

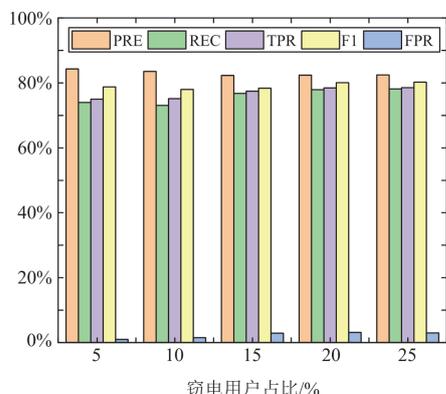


图 13 窃电检测性能随窃电用户比例变化对比图

Fig. 13 Comparison of electricity theft detection performance vs. proportion of electricity theft user

表 5 窃电检测性能随窃电用户比例变化结果

Table 5 Results of electricity theft detection performance vs. proportion of electricity theft user

窃电比例	ACC	PRE	REC	FPR	TPR	F1
5	81.23	84.27	73.95	1.03	74.98	78.77
10	81.41	83.54	73.08	1.56	75.13	77.96
15	81.99	82.28	76.72	2.93	77.41	78.39
20	82.50	82.37	77.94	3.17	78.45	80.09
25	82.54	82.44	78.15	3.02	78.50	80.24

由图 13 和表 5 可知, 随着窃电用户比例增加, 本文所提算法的 REC 和 TPR 整体呈上升趋势, 综合性能评价指标 F1 保持在 80%左右, 较为稳定, 表明所提算法窃电检测性能良好, 在不同窃电用户比例情况下仍能兼顾检出率、误检率等各项指标。PRE 指标下降 2%以内, 但仍保持在 82%以上, 表明本文所提算法在不同程度的不平衡数据集均具有

良好稳定的窃电检测性能, 可有效克服窃电用户比例变化的影响。

3.6 窃电检测模型对比分析

为验证所提方法的有效性及其模型结构的合理性, 采用相同网络结构的一维卷积网络和注意力机制方法 CNN+CBAM、时域卷积网络 TCN 及一维卷积网络 CNN 进行消融实验, 同时与 MLP、LSTM 方法进行对比实验, 各模型参数设置如表 6 所示。

表 6 检测方法与参数设置

方法	模型参数
ATCN	层属性: 时域卷积×4 使用卷积注意力模块机制: 是
CNN+CBAM	层属性: 一维卷积×4 使用卷积注意力模块机制: 是
TCN ^[21]	层属性: 时域卷积×4 使用卷积注意力模块机制: 否
CNN ^[22]	层属性: 一维卷积×4 使用卷积注意力模块机制: 否
MLP	层属性: 全连接层×3, 神经元数目: 16,32,64 使用卷积注意力模块机制: 否
LSTM ^[23]	层属性: LSTM 层×3, 神经元数目: 16,32,64 使用卷积注意力模块机制: 否

为保证各模型的参数量相同, 消融实验中将各模型基础参数均设定为使用 4 层卷积操作, 使用卷积通道数为[16, 32, 48, 64], 卷积核大小为 3、步长为 1、填充为 1, 都使用 ReLU 激活函数和最大值池化操作进行卷积层与层间的连接。在控制参数量基本一致的情况下, 各窃电检测方法对比如表 7 所示。

表 7 窃电检测方法对比

Table 7 Comparison of electric theft detection methods

方法	ACC	FACC	TPR	FPR	AUC
CNN	99.13	73.85	77.69	0.17	96.8
TCN	98.98	71.54	78.46	0.60	96.6
CNN+CBAM	98.80	73.08	77.69	0.90	97.0
ATCN	99.43	79.78	86.52	0.17	98.9
MLP	98.33	74.32	76.09	0.26	96.3
LSTM	98.26	71.39	75.51	0.73	96.6

由表 7 可知, 本文所提方法的各性能指标均优于现有常用方法, ATCN 比 CNN+CBAM 的 AUC 高出 2%, FACC 高出 6.7%, 表明本文采用的时域卷积结构具有更好的时序用电特征提取能力, 可更好地识别窃电行为。在 FPR 相近的情况下, 本文所提方法 TPR 高达 86.52%, 相较于其他窃电检测方法提高 8%以上, 且相比于 LSTM 提高 11%, 说明

本文模型可更全面、精准地捕捉潜在的窃电行为特征。实验结果表明，本文所提出的窃电检测方法能高效地从多源用电数据中捕捉窃电特征，满足实际复杂用电环境下高效准确窃电检测的需求。

3.7 窃电检测模型适用性分析

为分析本文所提算法在不同数据集上的适用性，利用爱尔兰智能电能表项目公开数据集对模型的适用性进一步进行验证，所构建的爱尔兰数据集信息如表 8 所示。

表 8 爱尔兰数据集信息

Table 8 Irish dataset information

数据集参数名称	参数值
样本个数	5000
时间跨度	2009 年 1 月 1 日—2010 年 6 月 20 日
训练:验证:测试	6:2:2
样本内容	用电功率、时间、温度
样本维度	720×3×1

利用式(10)对正常用户的用电数据进行篡改，构建窃电用户占比为 15%的数据集，并分别利用 MF-VAE ATCN、MF-VAE MLP 和 MF-VAE LSTM 进行窃电检测，窃电检测结果如表 9 和图 14 所示。

表 9 窃电检测结果

Table 9 Electricity theft detection results

方法	ACC	FACC	TPR	FPR	AUC
MF-VAE MLP	96.85	69.23	74.62	2.61	96.73
MF-VAE LSTM	97.42	71.67	77.08	1.89	97.40
MF-VAE ATCN	98.60	78.35	85.22	1.45	98.85

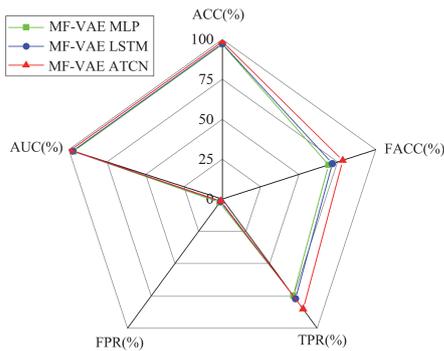


图 14 窃电检测结果对比图

Fig. 14 Comparison chart of electricity theft detection results

由表 9 和图 14 可知，本文所提算法在爱尔兰数据集上的窃电检测性能均高于 MF-VAE MLP 和 MF-VAE LSTM，其中误检率仅有 1.45%，综合评价指标 AUC 高达 98.85%，AUC 相比于其他两种算法提高 1.5%，说明本文所提算法对于不同数据集均具

有更好的窃电检测性能，适用性更强，具有良好的工程应用价值。

4 结论

本文提出了基于变分自编码器的多源数据融合窃电检测方法，实现了窃电行为的准确判别。实验结果表明：基于 TCN 结构引入注意力机制，使模型更加聚焦于窃电行为的敏感特征，从而提高了模型的泛化能力和窃电行为判别的准确率；构建的多维度特征提取变分自编码器对用户负荷数据、环境温度、时间以及对应台区相位、线损等多源数据进行特征提取，使模型所提取特征更具窃电行为区分度，可获得更好的窃电检测效果；本文所提窃电检测方法的 ACC、FACC、PRE、TPR、FPR、F1、AUC 等指标均优于其他检测方法，实用性强，泛化性好，可为电网公司判别窃电行为、稽查窃电用户提供准确高效的检测手段，减少窃电造成的电力损失，保障电网安全稳定运行。

参考文献

- [1] 陈启鑫, 郑可迪, 康重庆, 等. 异常用电的检测方法: 评述与展望[J]. 电力系统自动化, 2018, 42(17): 189-199. CHEN Qixin, ZHENG Kedi, KANG Chongqing, et al. Detection methods of abnormal electricity consumption behaviors: review and prospect[J]. Automation of Electric Power Systems, 2018, 42(17): 189-199.
- [2] CHUWA M G, WANG F. A review of non-technical loss attack models and detection methods in the smart grid[J]. Electric Power Systems Research, 2021, 199: 107415.
- [3] MESSINIS G M, HATZIARGYRIOU N D. Review of non-technical loss detection methods[J]. Electric Power Systems Research, 2018, 158: 250-266.
- [4] 李东东, 仇文杰, 周波, 等. 考虑源荷相关性及条件风险价值的综合能源系统参与电能市场-备用市场优化[J]. 电力系统保护与控制, 2024, 52(18): 24-34. LI Dongdong, QIU Wenjie, ZHOU Bo, et al. Optimization of an integrated energy system participating in energy and spinning reserve markets considering source-load correlation and conditional value of risk[J]. Power System Protection and Control, 2024, 52(18): 24-34.
- [5] 韩平平, 陈思远, 张楠, 等. 考虑分布式光伏的低压台区线损异常辨识方法[J]. 电力系统保护与控制, 2023, 51(8): 140-148. HAN Pingping, CHEN Siyuan, ZHANG Nan, et al. Line loss anomaly identification method for low-voltage station area considering distributed PV[J]. Power System Protection and Control, 2023, 51(8): 140-148.
- [6] 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, 2017, 14(4): 1606-1615.
- [7] 申永鹏, 孙嵩楠, 赫婷, 等. 基于数字人民币的智能电表及实时电力交易新模式[J]. 电力系统保护与控制, 2023, 51(7): 178-187.
SHEN Yongpeng, SUN Songnan, HE Ting, et al. Real-time power trading mode based on an e-CNY smart electricity meter[J]. Power System Protection and Control, 2023, 51(7): 178-187.
- [8] ZHENG K, CHEN Q, WANG Y, et al. A novel combined data-driven approach for electricity theft detection[J]. IEEE Transactions on Industrial Informatics, 2018, 15(3): 1809-1819.
- [9] 陈厚合, 丛前, 姜涛, 等. 多能协同的配电网供电恢复策略[J]. 电工技术学报, 2022, 37(3): 610-622.
CHEN Houhe, CONG Qian, JIANG Tao, et al. Distribution systems restoration with multi-energy synergy[J]. Transactions of China Electrotechnical Society, 2022, 37(3): 610-622.
- [10] 郑楷洪, 杨劲锋, 王鑫, 等. 用电量数据的可视化研究综述[J]. 电力系统保护与控制, 2022, 50(9): 179-187.
ZHENG Kaihong, YANG Jingfeng, WANG Xin, et al. Overview of visualization research on electricity consumption data[J]. Power System Protection and Control, 2022, 50(9): 179-187.
- [11] 严勤, 邓高峰, 胡涛, 等. 基于深度循环神经网络的异常用电检测方法[J]. 中国测试, 2021, 47(7): 99-104.
YAN Qin, DENG Gaofeng, HU Tao, et al. Abnormal electricity detection method based on deep recurrent neural network[J]. China Measurement & Test, 2021, 47(7): 99-104.
- [12] 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.
- [13] JÚNIOR L A P, RAMOS C C O, RODRIGUES D, et al. Unsupervised non-technical losses identification through optimum-path forest[J]. Electric Power Systems Research, 2016, 140: 413-423.
- [14] 郑思达, 梁琪琳, 彭鑫霞, 等. 基于模糊聚类的异常用电行为识别研究[J]. 电测与仪表, 2020, 57(19): 40-44.
ZHENG Sida, LIANG Qilin, PENG Xinxia, et al. Research on abnormal power consumption behavior identification based on fuzzy clustering[J]. Electrical Measurement & Instrumentation, 2020, 57(19): 40-44.
- [15] 田力, 向敏. 基于密度聚类技术的电力系统用电量异常分析算法[J]. 电力系统自动化, 2017, 41(5): 64-70.
TIAN Li, XIANG Min. Abnormal power consumption analysis based on density-based spatial clustering of applications with noise in power systems[J]. Automation of Electric Power Systems, 2017, 41(5): 64-70.
- [16] 王桂兰, 周国亮, 赵洪山, 等. 大规模用电数据流的快速聚类 and 异常检测技术[J]. 电力系统自动化, 2016, 40(24): 27-33.
WANG Guilan, ZHOU Guoliang, ZHAO Hongshan, et al. Fast clustering and anomaly detection technique for large scale power data stream[J]. Automation of Electric Power Systems, 2016, 40(24): 27-33.
- [17] 陈向群, 肖湘奇, 黄瑞, 等. 基于多维信息融合的窃电识别技术[J]. 湖南科技大学学报(自然科学版), 2022, 37(2): 73-78.
- [18] KARAMATLI E, CEMGIL A T, KIRBIZ S. Audio source separation using variational autoencoders and weak class supervision[J]. IEEE Signal Processing Letters, 2019, 26(9): 1349-1353.
- [19] LIU M, QIN H, CAO R, et al. Short-term load forecasting based on improved TCN and DenseNet[J]. IEEE Access, 2022, 10: 115945-115957.
- [20] GU D, GAO Y, LI Y, et al. A novel label-guided attention method for multilabel classification of multiple power quality disturbances[J]. IEEE Transactions on Industrial Informatics, 2022, 18(07): 4698-4706.
- [21] ARIF A, ALGHAMDI T A, KHAN Z A, et al. Towards efficient energy utilization using big data analytics in smart cities for electricity theft detection[J]. Big Data Research, 2022, 27: 100285.
- [22] BHAT R R, TREVIZAN R D, SENGUPTA R, et al. Identifying nontechnical power loss via spatial and temporal deep learning[C]//2016 15th IEEE International Conference on Machine Learning and Applications (ICMLA), December 18-20, 2016, Anaheim, CA, USA: 272-279.
- [23] ASLAM Z, JAVAID N, AHMAD A, et al. A combined deep learning and ensemble learning methodology to avoid electricity theft in smart grids[J]. Energies, 2020, 13(21): 5599.

收稿日期: 2024-03-06; 修回日期: 2024-10-02

作者简介:

蔡梓文(1991—), 男, 硕士研究生, 工程师, 研究员, 主要研究方向为营销安全与反窃电技术; E-mail: caizw@csg.cn

赵云(1985—), 男, 博士研究生, 正高级工程师, 主要研究方向为智能用电技术、窃电检测技术;

高云鹏(1978—), 男, 通信作者, 博士, 教授, 博士生导师, 主要研究方向为电能计量、智能信息处理。E-mail: gaoyunp@hnu.edu.cn

(编辑 魏小丽)