

Prediction Method of Power Stealing Based on Regression Convolutional Neural Network and Load Chaos Model *

JIN Haigang *, XIE Zhengang, REN Feng

(State Grid Shanxi Electric Power Company, Taiyuan Shanxi 030002, China)

Abstract: Accurate calculation of line loss and extraction of users' electricity consumption characteristics are the key to accurate marketing strategy. However, the randomness of renewable energy power generation, disorderly charging and discharging of electric vehicles, environmental changes and other factors make the user's electricity consumption behavior easily mutate, which leads to the chaotic and random characteristics of user's electricity consumption data in the station area, and can not effectively detect user's electricity stealing behavior. In order to solve this problem, a time-series correlation chaotic model of power consumption for station area users is established, and the characteristics of power stealing load samples and normal samples are extracted. The regression convolutional neural network is used to train and learn the power stealing samples and normal samples, and the enhanced feature classification learner is obtained, so as to realize the power consumption prediction for power stealing users. Through the test and analysis of the power consumption data of an actual power company, it shows that the calculation results of the proposed method have high accuracy.

Key words: regression convolution neural network; load; chaos; stealing electricity; forecast

EEACC: 7220; 8150

doi: 10.3969/j.issn.1005-9490.2023.01.038

基于回归卷积神经网络和负荷混沌模型的窃电预测方法 *

靳海岗 *, 谢振刚, 任 峰

(国网山西省电力公司, 山西 太原 030002)

摘 要: 精确地计算台区线损、提取用户用电特征实现窃电预测,是精准营销策略制定的关键。然而,台区可再生能源发电的随机性、电动汽车充放电无序性、环境变化等因素使用户用电行为极易突变,导致台区用户用电数据呈现混沌随机特性,无法有效检测用户窃电行为。对此,建立了台区用户用电的时序相关混沌模型,并提取窃电负荷样本与正常样本的特征,使用回归卷积神经网络对窃电样本和正常样本训练学习,获得增强特征分类学习器,以此实现对窃电用户用电预测。通过对某实际电力公司用电数据的测试分析表明,所提方法的计算结果具有较高的精确度。

关键词: 回归卷积神经网络; 负荷; 混沌; 窃电; 预测

中图分类号: TM744; TP181; TP183; O415.5

文献标识码: A

文章编号: 1005-9490(2023)01-0232-06

用户侧大量的窃电行为是一种人为恶意的对电网的攻击陋习,会对电力系统的节点电压水平和输电线路潮流边界稳定产生严重的安全威胁,同时也将造成发电、输电、配电、用电等各个环节运营成本的增加,因此对于用户侧窃电的预测具有重要的理论和实际意义^[1-2]。

随着泛在电力物联网建设的发展,对于需求侧精细化管理的要求日益提高,智能电表等高级量测设备已经大量装设于负荷侧,对于窃电行为的监视起到重要作用^[3-4]。然而,风力发电、光伏发电等大量并入配电网,其波动型、随机性造成需求侧的窃电行为检测和预报更加困难^[5]。

对于用户窃电行为的预测已经引起国内外电力应用工程师和理论分析专家的高度重视,成为目前

电力系统研究的热点,已出现许多很有理论和实际应用价值的成果,基本可以分为特征提取和分类识别两个步骤^[6]。

分类识别是窃电研究领域的重点,研究内容较多,其基本思路是将分类器获得的结果与实际结果建立映射关系,通过映射关系中的误差修正分类器学习参数,从而提高识别精度,如文献[7]提出了使用支持向量机进行用户用电数据训练,并采用提取的堆叠去相关自编码用电数据进行训练;为了克服支持向量机运算时间较长的问题,文献[8]提出皮尔森系数、贝叶斯网络以及决策树的窃电检测模型;文献[9]针对上述模型复杂度较高的问题,提出了随机森林的用户窃电检测方法;为了提高检测的精度,文献[10]提出了实值深度置信网络进行用户异

项目来源: 国网山西省电力公司科技项目(520531200004)

收稿日期: 2021-08-04

修改日期: 2021-12-15

常用电特征提取, 并采用因子分析进行窃电检测; 文献[11]根据窃电量与电表计量电量呈现正相关性, 提出了线损电量与窃电用电量之间的模型, 并采用格兰杰归因分析检测窃电用户; 文献[12]针对窃电数据的小样本特性, 提出了 Wasserstein 生成对抗网络的窃电样本过采样方法, 并使用神经网络进行生成器与对抗器的训练, 获得与真实窃电样本具有相近分布的样本; 文献[13]采用线性插值算法对配电网采集的缺失数据进行修补, 并建立台区线损波动率、线损和电流差异曲线的变点时间关联分析检测窃电行为; 文献[14-15]为了提高窃电检测的精度, 使用深度学习方法对窃电行为进行学习训练; 文献[16]针对单一分类方法的不足, 提出 k 最近邻、误差反向传播神经网络、梯度提升树、随机森林的多学习器集成的 Bagging 窃电检测方法。

总体来说, 目前对于窃电检测的研究已经取得一定的成果, 然而由于窃电行为的小样本性、不确定性、随机性导致目前的研究样本缺少、特征提取不足、识别精度欠佳。对此, 本文基于迁移学习理论, 建立窃电特征样本, 并提取其混沌模型特征, 使用回归卷积神经网络方法予以预测。

1 台区负荷混沌模型

台区负荷因为总量小, 极易受天气变化、环境因素、人类社会活动影响而产生较大的波动。同时, 由于可再生能源发电的大量并入, 其随机性、波动性发电, 使台区负荷变化无规则性加剧^[17]。

混沌模型是由美国科学家洛伦兹 Lorenz 于 1963 进行气象预测时发现混沌现象“蝴蝶效应”^[18], 由此提出混沌概念。混沌是指在一定的系统模型中, 随着时间变化, 系统状态呈现类似随机特征的物理现象。

对于台区负荷呈现出混沌现象的时间序列, 对该混沌序列进行相空间重构是进行负荷预测的重要方式^[19]。

1.1 负荷预测相空间重构

Pachard 和 Takens 等^[20]通过理论证明了对于具有混沌特征的时间序列, 通过构造表征原时间序列在拓扑意义下等价的坐标分量相空间, 能够获得混沌时间序列的规律和特征。

设负荷时间序列表示为:

$$P = \{x_i, i=1, 2, \dots, N\} \quad (1)$$

式中: x_i 表示时间 i 对应时刻的有功负荷; N 为正整数, 表示时间长度。

将时间序列 (1) 通过时间滞后器形成嵌入

向量:

$$X(t) = [x(t), x(t+\tau), \dots, x(t+(m-1)\tau)] \quad (2)$$

$$(t=1, 2, \dots, M)$$

式中: M 表示负荷向量构成的嵌入向量维数; τ 表示时间滞后器设置的延迟时间。

式 (1) 中的时间长度 N 与式 (2) 中时间 M 的关系为:

$$M = N - (m-1)\tau \quad (3)$$

式 (1) 是台区负荷随时间变化的动态数据, 将其变化为重构的式 (2), 描述了 m 维相空间中的动态变化轨迹, 形成了其混沌模型。

理论研究和实际应用证明^[21-22], 通过选择合适的相空间维数 m 和滞后器时间 τ , 那么相空间与原始负荷具有相同的拓扑意义和性质。

1.2 负荷数据的归一化

为了获得相对平稳的负荷预测源域数据, 对式 (2) 重构的负荷相空间归一化为:

$$x'_i = \frac{x_i - \min(x_i)}{\max(x_i) - \min(x_i)} \quad (4)$$

式中: x_i 表示式 (2) 中的元素, $i=1, 2, \dots, M$; x'_i 表示归一化后的元素; $\min(x_i)$ 表示 $x_i (i=1, 2, \dots, M)$ 最小值, $\max(x_i)$ 表示其最大值。

1.3 相空间延迟时间获取

对于式 (1) 和式 (2) 的负荷时间序列, 设 $x(k)$ 在式 (1) 中出现的概率为 $P\{x(k)\}$, $X(k)$ 在式 (2) 中出现的概率为 $P\{X(k+\tau)\}$, 则二者之间的联合概率可以表示为 $P\{x(k), X(k+\tau)\}$ 。

$P\{x(k)\}$ 和 $P\{X(k+\tau)\}$ 的互信息可以表示为:

$$I(\tau) = \sum_{i=1}^N P\{x(k), X(k+\tau)\} \cdot \lg \left\{ \frac{P\{x(k), X(k+\tau)\}}{P\{x(k)\}P\{X(k+\tau)\}} \right\} \quad (5)$$

按照互信息定义, 当式 (5) 的非线性函数取第一个极小值时, 此时函数之间具有最大的独立性和最小的冗余性, 由此确定此时的 τ 数值。

1.4 嵌入向量维数的获取

伪最近邻值法能够根据其最佳准则^[23]获取相空间中的嵌入维数:

$$\|X(i), X(j)\| = \left\{ \sum_{l=0}^{m-1} [x(i+l\tau) - x(j+l\tau)]^2 \right\}^{1/2} \quad (6)$$

式中: $\|X(i), X(j)\|$ 表示数据 $X(i)$ 和 $X(j)$ 之间的欧式空间距离。

对式 (6) 可以进行判断, 以获取最邻近的数据:

$$\sqrt{\frac{R_{m+1}^2(i,j) - R_m^2(i,j)}{R_m^2(i,j)}} = \frac{|x(i+m\tau) - x(j+m\tau)|}{R_m(i,j)} \geq R_{tol} \quad (7)$$

式中: $R_{m+1}^2(i,j)$, $R_m^2(i,j)$ 分别表示相空间维数为 $m+1$ 和 m 时的欧式距离平方; R_{tol} 为设置的阈值, 本文经过测试取 16。

对式(6)和式(7)进行 m 由 1 不断增大的迭代计算, 并以混沌吸引之间的打开程度 90% 以上作为标准, 获取此时的 m 数值, 并确定为最佳相空间嵌入维数。

2 源域目标域迁移学习建模

由于窃电行为是偶然发生的小样本事件, 利用机器学习原理对该小样本事件进行学习的效果较差, 因此本文提出使用迁移学习的方法解决该问题。

迁移学习是一种能够将缺失或者小样本的历史数据进行特征提取并能够获得较高识别精度的方法^[24]。

该方法是在源域中对目标域的公共映射进行邻域自适应学习, 实现学习结果的跨域传递, 从而能够对目标域的数据信息识别, 解决目标域中历史数据量少、样本残缺、样本异常等问题。

设迁移学习的源域为:

$$D_s = \{(x_{si}, y_{si})\} \quad (i=0, 1, 2, \dots, n_s-1) \quad (8)$$

式中: n_s 表示源域中的学习样本总数; x_{si} 表示源域中的第 i 个样本, y_{si} 表示该样本对应的标记, 通常设置为:

$$y_{si} \in \{0, 1, 2, \dots, C-1\} \quad (9)$$

式中: C 表示正整数。

设迁移学习的目标域表示为:

$$D_t = \{x_{tj}\} \quad (j=0, 1, 2, \dots, n_t-1) \quad (10)$$

式中: n_t 表示目标域中的数据总数; x_{tj} 表示目标域中第 j 个数据。

一般来说, 源域中的样本总数与目标域中的数据总数不相等, 且二者的概率不相等, 为了降低源域和目标域之间的信息损失, 采用目标域和源域之间的对抗自适应网络降低二者之间的分布偏差。设在学习过程中的 G_f 表示特征提取器, G_d 表示数据来源判别器, G_c 表示数据分类器, 定义学习方法的损失函数为:

$$L = \frac{1}{n_s} \sum_{x_i \in D_s} L_c\{G_c(G_f(x_i), c_i)\} - \frac{\lambda}{n_s + n_t} \sum_{x_i \in \{D_s \cup D_t\}} L_d\{G_d(G_f(x_i), d_i)\} \quad (11)$$

式中: λ 表示源域和目标域的损失参数; L_c 表示源域

分类损失函数; L_d 表示目标域损失函数; c_i 表示源域分类标签; d_i 表示 x_i 的域标签。

式(11)中的 G_c 通常使用下列计算模型:

$$G_c = \frac{e^{h_c}}{\sum_{c=0}^{C-1} e^{h_c}} \quad (12)$$

式中: h_c 表示 G_c 函数第 c 个元素上的数值。

通常为了简化计算, G_d 选择式(12)形式。为了使式(11)的损失函数最小, 建立如下的优化模型:

$$\begin{cases} (\hat{W}, \hat{v}, \hat{b}, \hat{c}) = \operatorname{argmin} E(W, v, b, c, \hat{u}, \hat{z}) \\ (\hat{u}, \hat{z}) = \operatorname{argmax} E(\hat{W}, \hat{v}, \hat{b}, \hat{c}, \hat{u}, \hat{z}) \end{cases} \quad (13)$$

式中: G_f 特征提取器的参数为 W 和 v , 分别表示其权值和偏置量; b 和 c 为 G_c 的参数; u 和 z 为 G_d 的参数; 函数 $E(\cdot)$ 表示概率期望。

式(13)的最小化最大化优化问题可以建模为如下优化函数:

$$f = \min \max E(F, C, D) \quad (14)$$

式中: 参数 F 、 C 和 D 分别表示 G_f 、 G_c 和 G_d 。

3 回归卷积迁移神经网络

3.1 卷积神经网络

传统的卷积神经网络主要由输入层、卷积层、全连接层和输出层构成, 如图 1 所示, 计算模型如图 1 所示^[25]:




图 1 卷积神经网络结构图

由图 1 可见, 卷积层主要是最左侧的信号输入部分, 并采用奇数范围内的卷积和函数进行多层深度卷积运算, 然后在激活函数的作用下进行非线性放射变换。池化层是对卷积层获得的计算结果进行归纳, 并按照最大值池化法则进行优化; 全连接层中采用 BP 神经网络对池化层的优化结果进行特征总结。卷积层、池化层和全连接层的计算方式为:

$$\begin{cases} r_i = \sigma\{W_r \cdot [h_{i-1}, x_i]\} \\ z_i = \sigma\{W_z \cdot [h_{i-1}, x_i]\} \\ h_i = \tanh\{W_h \cdot [r_i \times h_{i-1}, x_i]\} \\ h'_i = (I - z_i) \times h_{i-1} + z_i \times h_i \\ y_i = \sigma(W_o \cdot h_i) \end{cases} \quad (15)$$

式中: x_t 表示 t 时刻的输入信号构成的向量; h_{t-1} 表示 $t-1$ 时刻计算保存结果; h_t 表示 t 时刻计算结果; r_t 表示更新门在 t 时刻的状态向量; z_t 表示 t 时刻重置门的状态向量; h'_t 表示 t 时刻对输入信号及上一时刻结果计算结果; y_t 表示 t 时刻计算结果; W_r 、 W_z 、 W_h 、 W_o 表示权值向量; I 表示单位矩阵; 符号 $[]$ 表示向量之间的连接方式; 符号 $\cdot$ 表示矩阵之间的点乘计算方式; 符号 $\times$ 表示矩阵或者向量之间的乘积; 函数 $\sigma(\cdot)$ 表示 sigmoid 激活函数。

3.2 回归卷积神经网络

卷积神经网络的目标是对源域的输入数据进行训练, 获得学习参数, 并用于目标域的识别。为了减少学习参数的误差, 本文使用支持向量机的回归卷积神经网络, 其分类平面和欧式距离分别定义为:

$$f(x) = w^T x_n + b \quad (16)$$

$$y_i - f(x) = y_i - w^T b < \xi \quad (17)$$

式中: $f(x)$ 表示分类超平面函数; y_i 表示第 i 个数据对应的标记; w^T 表示权值; b 为偏置量; ξ 表示距离; x_n 表示输入的数据样本向量。

式(17)为了寻找优化的回归系数, 构建松弛优化模型为:

$$\begin{cases} f = \min_{w, b} \left\{ \frac{1}{2} w^T w + \gamma \sum_{i=1}^n (\zeta_i + \zeta_i^*) \right\} \\ \text{s.t. } y_i - f(x) \leq \xi + \zeta_i \\ f(x) - y_i \leq \xi + \zeta_i^* \\ \zeta_i, \zeta_i^* \geq 0, i = 1, 2, \dots, n \end{cases} \quad (18)$$

式中: ζ_i 和 ζ_i^* 表示优化模型的松弛变量; γ 表示惩罚系数。

3.3 改进的回归卷积神经网络

式(16)~式(18)中的输入数据 x_n 和 y_i 都来自于源域, 随着源域中采集数据按时间推移, 源域中数据样本与目标域中的样本关联映射关系会发生变化, 进而影响式(18)参数精度的计算。因此需要对源域数据进行自适应更新。

设对于任意源域样本:

$$\{(x_i^{(t)}, y_i^{(t)}), \quad t = 1, 2, \dots, m\} \quad (19)$$

式中: 上标 t 表示时间, 其他含义与式(8)含义相同。

设目标域数据样本参考序列为 x_0 , 那么参考序列与源域中的关联样本点的系数计算公式为:

$$\begin{cases} \eta_i(t) = \frac{a}{b} \\ a = \min_i \min_t |x_0^{(t)} - x_i^{(t)}| + \rho \max_i \max_t |x_0^{(t)} - x_i^{(t)}| \\ b = |x_0^{(t)} - x_i^{(t)}| + \rho \max_i \max_t |x_0^{(t)} - x_i^{(t)}| \end{cases} \quad (20)$$

式中: $x_0^{(t)}$ 表示参考序列 x_0 在 t 时刻的负荷值; ρ 为

相似系数, 本文取 0.5。

对式(20)计算得到的系数取均值, 就是目标域与源域的关联相似度:

$$r_i = \frac{1}{N} \sum_{t=1}^N \eta_i(t) \quad (21)$$

式中: N 表示数据总数。

通过设置时间窗口不断移动时间, 获取不同时间段内的源域数据集, 进而可以获得式(21)关联相似度较大(本文取 90%)的数据样本。

4 算例分析

为了验证本文所提算法的有效性, 使用某实际电网 100 个用户在 2016 年 8 月至 9 月共 60 天, 每天 24 h、每小时以 15 min 为间隔采集的负荷用电数据, 总计 5 760 条负荷数据进行测验。

选择前 50 天共 4 800 条负荷数据作为源域, 选择后 10 天共 960 条负荷数据作为目标域。源域数据集中窃电数据共 578 条, 其余 4 222 条数据为正常数据, 窃电数据占比 12%。目标域中窃电数据 380 条, 其余 580 条为正常数据, 窃电数据占比 40%。

由于实际台区负荷随机波动性较大, 对实际负荷曲线进行混沌模型建模, 由此形成具有迁移学习特性的负荷模型。通过与原始负荷曲线对比结果如表 1 所示。

表 1 预测负荷结果(标么值)

用户编号	精度/%	用户编号	精度/%
1	96.25	11	96.65
2	96.38	12	98.67
3	97.51	13	97.54
4	97.24	14	96.32
5	96.92	15	97.28
6	98.33	16	98.26
7	97.27	17	98.67
8	96.39	18	98.54
9	98.61	19	97.62
10	97.24	20	97.58

为了提高目标域窃电行为辨识的准确率, 在混沌模型基础上, 模拟源域的窃电行为, 并形成多样本窃电特征曲线。部分负荷数据如图 2 所示, 图 2 中




图 2 部分负荷数据

显示了正常负荷曲线和部分窃电负荷,正常负荷为图中的聚集区域,窃电负荷用电量比正常负荷部分增大。

使用一台计算机,中央处理器为 Intel Core i5-7500 3.4 GHz 核,内存为 8G,显卡为 NVIDIA GTX960。使用 PyCharm 软件 TensorFlow 深度学习软件编写算法程序。深度学习优化算法使用 Adam 核优化器,设置初始学习速率为 0.000 01,后续学习速率 epoch 自适应调整,动量系数设置为 0.6,每批训练块大小设置为 64,训练迭代次数设置为 1 万次。

源域训练过程如图 3 所示,图 3 中的横坐标表示迭代次数,每迭代一次表示训练模型更新一次,平均每迭代一次的时间大约为 0.2 s,纵坐标表示训练过程的精度,当训练迭代次数达到 6 000 次以后,在目标域上的准确率可达到 90%左右,当达到 8 000 次后,精度达到 95%并趋向稳定,此时系统占用内存为 87.6 MB。




图 3 训练迭代次数与准确率之间的关系

实验过程中提取得到的部分窃电负荷样本和正常样本的特征曲线如图 4 所示。




图 4 圆点标注显示异常用电点

为了与传统支持向量机(Support Vector Machine, SVM)方法、神经网络方法(Back Propagation, BP)、传统卷积神经网络方法(Convolutional Neural Networks, CNN)、深度学习中的长短期记忆网络(Long Short-Term Memory, LSTM)进行比较,本实验进行了 5 次取均值,结果如表 2 所示。

为了进一步与已有文献所提方法对比,选取具有代表性的文献[7]、文献[9]、文献[10]、文献[13]进行测试,测试结果如表 3 所示。

表 2 不同方法窃电预测结果对比

方法类型	精度/%
SVM	79.65
BP	82.37
CNN	84.54
LSTM	88.78
本文	96.57

表 3 与现有文献方法对比结果

文献	精度/%
文献[7]	94.324
文献[9]	95.125
文献[10]	94.586
文献[13]	94.578
本文	96.575

通过表 2 和表 3 可见,本文所提方法能够获得较高的窃电预测精度,原因是建立了迁移学习方法获得大量样本,从而进行的卷积神经网络学习能够获得较好的效果。

为了进一步测试算例,选择源域为 55 天共 5 280 条负荷数据进行训练,目标域选择后 5 天共 480 条负荷数据进行测试。训练次数与准确率之间的关系如图 5 所示。




图 5 增加样本后训练迭代与准确率之间关系

由图 5 可见,随着训练样本数量的增加,准确率也略有上升,当迭代次数达到 8 000 时,精度达到 96.7%,相比图 3 略有提升。

4 结论

针对窃电对电力系统安全稳定运行产生的威胁,以及增加的电网安全经济运行成本,本文提出了负荷混沌模型结合回归卷积神经网络的窃电预测方法,通过仿真算例可得如下结论:

①使用负荷混沌预测模型能够精确地获得台区负荷预测结果;

②迁移学习方法能够产生大量真实可靠的窃电负荷样本,并用于源域训练学习;

③使用回归卷积神经网络方法能够获得较高的窃电预测精度。

通过对实际算例的仿真,可以发现,对于缺少样

本的窃电行为,通过构建迁移学习,建立大窃电样本,并自适应调整与目标域切合度,能够有效提高预测精度。后续将继续研究该问题,如高精度地建立目标域和源域之间的切合度样本,选择合适的源域样本用于训练等问题,使该研究更加符合实际,从而更好地服务实际。

参考文献:

- [1] 朱继忠,冯禹清,谢平平,等. 考虑可再生能源配额制的中国电力市场均衡模型[J]. 电力系统自动化, 2019, 43(21): 71-79.
- [2] 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.
- [3] He Y B, 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.
- [4] Jeong S H, Lee J W, Yoon G H, et al. Topology Optimization Considering the Fatigue Constraint of Variable Amplitude Load Based on the Equivalent Static Load Approach[J]. Applied Mathematical Modelling, 2018, 56: 626-647.
- [5] 郭红霞,陆进危,杨苹,等. 非侵入式负荷监测关键技术问题研究综述[J]. 电力自动化设备, 2021, 41(1): 135-146.
- [6] 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.
- [7] 胡天宇,郭庆来,孙宏斌. 基于堆叠去相关自编码器和支撑向量机的窃电检测[J]. 电力系统自动化, 2019, 43(1): 119-125.
- [8] Monedero I, Biscarri F, León C, et al. Detection of Frauds and Other Non-Technical Losses in a Power Utility Using Pearson Coefficient, Bayesian Networks and Decision Trees[J]. International Journal of Electrical Power & Energy Systems, 2012, 34(1): 90-98.
- [9] 许刚,谈元鹏,戴腾辉. 稀疏随机森林下的用电侧异常行为模式检测[J]. 电网技术, 2017, 41(6): 1964-1971.
- [10] 张承智,肖先勇,郑子萱. 基于实值深度置信网络的用戶侧窃电行为检测[J]. 电网技术, 2019, 43(3): 1083-1091.
- [11] 金晟,苏盛,曹一家,等. 基于格兰杰归因分析的高损台区窃电检测[J]. 电力系统自动化, 2020, 44(23): 82-89.
- [12] 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.
- [13] 唐冬来,刘友波,熊智临,等. 基于时空关联矩阵的配电台区反窃电预警方法[J]. 电力系统自动化, 2020, 44(19): 168-176.
- [14] 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.
- [15] 张宇帆,艾芊,李昭昱,等. 基于特征提取的面向边缘数据中心的窃电检测[J]. 电力系统自动化, 2020, 44(9): 128-134.
- [16] 游文霞,申坤,杨楠,等. 基于 Bagging 异质集成学习的窃电检测[J]. 电力系统自动化, 2021, 45(2): 105-113.
- [17] 葛少云,李吉峰,刘洪,等. 考虑物理特征与行为因素的家庭用能特性建模[J]. 电力自动化设备, 2019, 39(3): 36-44.
- [18] 马宏忠,严岩. 基于混沌理论和 GOA-K-means 算法的有载分接开关状态特征分析计算方法[J]. 电工技术学报, 2021, 36(4): 1399-1406.
- [19] 乔伟彪,陈保东,卢泓方. 基于混沌理论和 Volterra 自适应滤波器的天然气负荷预测[J]. 中国科学: 技术科学, 2015, 45(1): 91-102.
- [20] 张华强,张晓燕. 基于混沌理论和 LSSVM 的蒸汽负荷预测[J]. 系统工程理论与实践, 2013, 33(4): 1058-1066.
- [21] 张金良,谭忠富. 基于经验模态分解和计量经济学模型及混沌模型的短期负荷预测[J]. 电网技术, 2011, 35(9): 181-187.
- [22] 彭虹桥,顾洁,胡玉,等. 基于混沌粒子群-高斯过程回归的饱和负荷概率预测模型[J]. 电力系统自动化, 2017, 41(21): 25-32.
- [23] Kennel M B, Brown R, Abarbanel H D I. Determining Embedding Dimension for Phase Space Reconstruction Using a Geometrical Reconstruction[J]. Physical Review A, 1992, 45(6): 3403-3411.
- [24] 庄福振,罗平,何清,等. 迁移学习的研究进展[J]. 软件学报, 2015, 26(1): 26-39.
- [25] 梁煜,张金铭,张为. 一种改进的卷积神经网络的室内深度估计方法[J]. 天津大学学报, 2020, 53(8): 840-846.



靳海岗(1972—),男,山西临汾人,高级工程师,硕士学位,主要研究方向:从事电能计量技术、数字化计量技术研究工作,15333664600@189.com。