

基于智能电能表数据挖掘的用户异常用电行为检测策略

钟磊¹, 姜雪娇¹, 吴海杰², 吴民¹, 孙延松¹, 徐佳隆¹

(1. 海南电网有限责任公司, 海口 570010; 2. 南方电网数字电网集团(海南)有限公司, 海口 570010)

摘要: 高效的用户异常用电行为检测是保证电网安全稳定的基础, 针对现有用户异常用电行为检测方法存在的准确率差和效率低等问题, 基于电能信息采集系统, 提出一种将改进 K-means 算法、改进动态时间规整算法(dynamic time warping, DTW)和 Stacking 集成学习算法相结合的用户异常用电行为检测策略。通过改进 K-means 算法完成用户用电行为的特征曲线聚类, 通过改进的时间动态弯曲算法完成用户异常用电初筛, 通过 Stacking 集成学习算法判断用户异常用电行为。通过实验验证其优越性。结果表明, 所提方法与常规检测方法相比具有最佳检测性能, 检测准确率为 99.93%, 检测时间为 8.32 s。可为电网安全提供技术支撑。

关键词: 智能电网数据; 异常用电行为; K-means 算法; 时间动态弯曲算法; Stacking 集成学习算法

DOI:10.19753/j.issn1001-1390.2026.09.018

中图分类号: TM93

文献标识码: A

文章编号: 1001-1390(2026)09-0183-09

User abnormal electricity consumption behavior detection strategy based on smart electricity meter data mining

Zhong Lei¹, Jiang Xuejiao¹, Wu Haijie², Wu Min¹, Sun Yansong¹, Xu Jialong¹

(1. Hainan Power Grid Co., Ltd., Haikou 570010, China.

2. China Southern Power Grid Digital Grid Group (Hainan) Co., Ltd., Haikou 570010, China)

Abstract: Efficient detection of abnormal user electricity consumption behavior is the foundation for ensuring the safety and stability of the power grid, in response to the problems of poor accuracy and low efficiency in existing detection methods for abnormal user electricity consumption behavior, a user abnormal electricity consumption behavior detection strategy is proposed based on an electric energy information collection system, which combines an improved K-means algorithm, an improved time dynamic bending algorithm, and a Stacking ensemble learning algorithm. By improving the K-means algorithm to cluster the characteristic curves of user electricity consumption behavior, the time dynamic bending algorithm to complete the initial screening of user abnormal electricity consumption, by using the Stacking ensemble learning algorithm to determine user abnormal electricity consumption behavior. Its superiority is verified through experiments. The results indicate that, the proposed method has the best detection performance compared to conventional detection methods, with a detection accuracy of 99.93% and a detection time of 8.32 seconds. It can provide certain assistance for the safety of the power grid.

Keywords: smart grid data, abnormal electricity consumption behavior, K-means algorithm, time dynamic bending algorithm, Stacking ensemble learning algorithm

0 引言

随着我国提出“双碳”这一目标,新时代对电力系统的要求也越来越严格^[1-2]。为了满足这一目标,需要采取一系列措施来提高电力系统的灵活性

和可持续性。智能电能表的广泛普及不仅提高了电力系统的运行效率和服务质量,也为消费者带来了更加透明、自主的用电体验^[3-4]。电力企业获取大量用户侧用电数据,如何从用户侧用电数据中挖掘有用信息,自动识别用户的异常用电行为,提高异常用电行为的检测效率,对电力企业的健康发展具有重要意义。

基金项目: 中国南方电网有限责任公司科技项目(ZN-YD-007)

目前,国内外关于用户异常用电检测方法的研究主要集中在设备检测 and 数据分析两个方面^[5]。尽管设备检测方法在用户异常用电检测中具有一定的应用价值,但其高昂的成本和需要持续的维护使其应用受限。相比之下,基于机器学习的数据分析方法因其灵活性、可扩展性和不断进步的技术而显示出更大的潜力。在文献[6]中,针对用电数据类别不均衡,提出将 Stacking 集成学习模型用于电力用户窃电检测。结果表明,所提方法能够有效解决数据类别不均衡问题,充分发挥各学习器优势。在文献[7]中,针对低压窃电负荷小,难以被发现,提出一种自回归移动平均模型和递归贝叶斯相结合用于低压窃电检测。结果表明,所提方法可以及时准确地发现低压窃电行为。在文献[8]中,针对现有用户异常用电行为检测方法无法快速准确地判别异常情况,提出将变分模式分解和改进自回归滑动平均模型相结合的用户异常用电行为检测方法。结果表明,该方法在大数据和非高斯分布时具有更好的便利性和效率。在文献[9]中,针对现有用户异常用电行为检测方法检测效率低的问题,提出将卷积神经网络、网络搜索算法和支持向量机相结合的用户异常用电行为检测方法。结果表明,与常规方法相比,该方法具有更好的检测精度和效率。在文献[10]中,针对现有用户异常用电行为检测方法检测准确率低的问题,提出了一种改进的支持向量机用于用户异常用电行为检测。结果表明,该方法与常规方法相比,检测精度最大提高 1.8%,误差也相对较小。在文献[11]中,针对电力用户异常电力行为引起的电网非技术性损失,提出用于用户异常用电行为检测的 Stacking 综合模型。结果表明,该方法比单一模型具有更高效的检测性能。上述方法虽然一定程度上提高了电力用户异常用电行为检测的准确性和效率,但距离准确率大于 98% (即在检测中能正确识别出绝大多数的异常用电行为,同时保持低的误报率) 和效率达到实时分析仍存在一定的差距。

在上述研究的基础上,提出一种改进 K-means 算法、改进时间动态弯曲算法 (dynamic time warping, DTW) 和 Stacking 集成学习算法相结合的用户异常用电行为检测策略。通过改进 K-means 算法完成用户用电行为的特征曲线聚类,通过改进 DTW 完成异常初筛,通过 Stacking 集成学习算法完

成异常最终检测。并通过实验验证其优越性。

1 电能信息采集系统概述

电能信息采集系统的结构如图 1 所示,主要包括以下几个部分:

- 1) 现场监测设备:作为系统中的基础设备,主要由电能表和监测设备组成;
- 2) 数据采集层:现场监测设备通过电力载波将数据传输采集终端,采集终端将数据传输到主站;
- 3) 通信网络:数据采集系统通过 5G/GPRS (general packet radio service)/光纤/以太网等多种通信方式将数据传输到主站;
- 4) 主站:负责采集电能信息的接收、存储、管理,以及数据的分析和处理,为电力公司提供决策支持。

整个电能信息采集系统实现了用电数据的自动采集、传输和管理,提高了电力公司的工作效率,降低了运营成本,同时为用户提供了更加方便、智能的用电服务。




图 1 电能信息采集系统结构

Fig. 1 Structure of electric energy information collection system

2 用户异常用电行为检测

2.1 改进 K-means 算法特征曲线聚类

K-means 算法是一种广泛用于无监督学习的聚类算法,本文通过改进 K-means 算法完成用户用电行为的特征曲线聚类^[12-13]。K-means 算法的核心目标是将一个数据集划分为 K 个不同的集群,每个数据点属于距离其最近的均值 (聚类中心) 对应的簇。步骤如下:

- 步骤 1: 随机选择 K 个初始聚类中心 $c_1, c_2, \dots, c_K$;
- 步骤 2: 通过欧式距离划分类别;
- 步骤 3: 计算样本点的平均值作为新的聚类中

心,如式(1)所示:

$$c_j(i) = \frac{1}{n_j} \sum_{x_i \in c_j} x_i, \quad j = 1, 2, \dots, K \quad (1)$$

式中: x_i 为第 i 个样本点; $c_j(i)$ 为聚类中心 c_j 中样本点平均值; n_j 为聚类中心 c_j 的样本数;

步骤 4:重复上述两个步骤直到满足终止条件,聚类中心不再改变,即平方准则误差函数收敛,误差平方和 E 如式(2)所示:

$$E = \sum_{i=1}^k \sum_{x \in c_i} |x - m_i|^2 \quad (2)$$

式中: m_i 为 c_i 的中心。

K-means 算法的优点在于实现简单,在数据集较大的情况下也能够有效地工作,因为每次迭代的计算复杂度与数据点的数量线性相关。但缺点也非常明显,聚类结果容易受到初始聚类中心点选择的影响,算法需要手动预设聚类数。通过以下两个优化来解决上述问题。

1) 利用改进的剑鱼算法优化聚类中心^[14]

剑鱼算法 (swordfish algorithm, SFA) 作为一种群体智能优化算法,模拟剑鱼捕食行为的特点^[15]。在解决优化问题时具有一定的优势,但也存在易陷入局部极值、种群多样性减少等问题,文中通过 Tent 混沌搜索解决上述问题。

Tent 混沌映射增加种群的多样性,如式(3)所示:

$$x_{i+1} = \begin{cases} x_i, & x_i < 0.7 \\ 0.7, & x_i \geq 0.7 \end{cases} \quad (3)$$

Tent 混沌扰动改善易陷入局部极值,对个体产生混沌扰动,如式(4)所示:

$$x'_{\text{new}} = \frac{x'}{2} + \frac{x_{\text{new}}}{2} \quad (4)$$

式中: x' 、 x_{new} 、 x'_{new} 分别为施加个体、混沌扰动量和经历扰动后个体;

2) 间隙统计算法和肘形判据确定 K 值^[16]

间隙统计算法 (gap static algorithm, GSA) 和肘形判据结合是确定聚类算法中最佳聚类数的方法。利用肘形判据初步找到一个合适的范围,再结合间隙统计算法进一步验证和细化选择。

改进 K-means 算法特征曲线聚类过程如下:

步骤 1:输入参数:输入采样数、采样维数、聚类

中心数等;

步骤 2:对算法初始化;

步骤 3:用式(3)初始化剑鱼和沙丁鱼;

步骤 4:计算适应度值,更新剑鱼和沙丁鱼的位置;

步骤 5:每次迭代后,判断剑鱼适应值是否大于平均适应值,大于则通过式(4)进行混沌扰动;

步骤 6:当达到最大迭代次数或其他结束条件时,该算法结束,输出最优聚类结果。否则,返回步骤 3 继续迭代。

2.2 改进 DTW 用户异常用电行为初筛

通过改进 K-means 算法完成用户负荷特征曲线聚类,将用电规律类似的归为同一类。由于用户较多,通过相似度对用户异常进行初筛,提高后期检测效率。本文通过 DTW 算法对用户异常用电进行初筛。

在起始端和末端出现大的局部欧几里德距离,即边缘效应,DTW 算法输出值异常增加。为了解决这个问题,本文引入加权函数进行优化,并对每个步骤的欧几里德距离进行加权,如式(5)和式(6)所示^[17]:

$$D_{\text{wdtw}}(X, Y) = \sum_{k=1}^s \omega_k d_k \quad (5)$$

$$\omega_k = \begin{cases} k/H, & 1 \leq k \leq H \\ 1.5, & H < k \leq s-H \\ (s-k)/H, & s-H < k \leq s \end{cases} \quad (6)$$

式中: X 为待测用户负荷曲线; Y 为负荷特征曲线; d_k 为第 k 条路径距离; ω_k 为加权函数; H 为整定系数。

DTW 算法在搜索最优路径时需要搜索整个区域,但在识别过程中,由于路径倾斜的限制,某些网格无法到达,不需要保存所有累积距离和帧匹配距离。因此,可以约束全局路径搜索范围,以防止扩展搜索区域。约束区域如图 2 所示。

如果待测用户负荷曲线表示为 $X = [x_1, x_2, \dots, x_N]$, 负荷特征曲线表示为 $Y = [y_1, y_2, \dots, y_M]$, 那么相似度公式如式(7)所示:

$$S = \frac{1}{1 + D_{\text{wdtw}}(X, Y)} \quad (7)$$

式中: S 为待测用户的负荷曲线和负荷特性曲线的相似度; $D_{\text{wdtw}}(X, Y)$ 为 X 和 Y 最小弯曲的总代价。

用户异常用电行为的初筛步骤如下:

步骤 1: 输入负载曲线数据;
步骤 2: 对数据进行预处理;
步骤 3: 进行相似度计算;
步骤 4: 设置相似度阈值;

步骤 5: 若相似度低于该阈值, 则初步判定该用户为异常用户; 反之, 若相似度不低于阈值, 则认定该用户为正常用户。




图 2 DTW 算法全局路径约束区域

Fig. 2 DTW algorithm global path constraint region

2.3 Stacking 集成算法用户异常用电行为检测

采用 Stacking 综合学习方法检查用户的异常用电行为。Stacking 综合模型是一种集成学习方法, 它通过将不同类型基础学习器的预测结果作为输入特征来训练一个元学习器, 以此来整合多个模型的优势^[18-21]。下面是对 Stacking 模型两层结构的具体分析:

第 1 层: 基础学习器: 在第一层中, 选择多种不同类型的基础学习器来从多角度分析数据;

第 2 层: 元学习器: 在第二层中, 元学习器的任务是组合第一层中各个基础学习器的预测结果。

通过 5 折交叉验证进行模型融合完成特征分类。根据基学习器的检测能力, 在 Stacking 模型的第 1 层选择极限梯度提升决策树 XGBoost 模型、随机森林、梯度提升决策树 GBDT。这是因为随机森林中各决策树的输入不完全相同, 提高了模型的泛化能力, 在采样过程中通过并行采样提高了模型训练和分类的速度。GBDT 适用于高维数据, 并且具有强大的学习能力和并行处理能力。而 XGBoost 增加了正则化项, 有效防止过拟合, 并且在效率上有所提升。

在 Stacking 模型的第二层选择泛化能力强的模

型是至关重要的。这是因为第二层的元学习器的任务是整合第一层中各个基础学习器的预测结果。如果泛化能力不足, 无法有效地总结和纠正第一层学习器的偏差。随机森林具有较强的泛化能力, 文中选择随机森林作为第二层的元学习器。模型结构如图 3 所示。




图 3 模型结构

Fig. 3 Model structure

2.4 用户异常用电行为检测策略

所提用户异常用电行为检测步骤如下所示:

- 步骤 1: 输入参数: 输入采样数、采样维数、聚类中心数等;
 - 步骤 2: 对算法进行初始化;
 - 步骤 3: 通过改进的 K-means 算法对特征曲线进行聚类;
 - 步骤 4: 当达到最大迭代次数或其他结束条件时, 该算法结束, 输出最优聚类结果;
 - 步骤 5: 根据不同类别输入负载曲线数据;
 - 步骤 6: 对 进行相似度计算;
 - 步骤 7: 设置相似度阈值;
 - 步骤 8: 相似度小于阈值, 则判定为异常用户。需要进一步判断初筛的异常用户;
 - 步骤 9: 将初筛异常用户输入 Stacking 集成学习模型进行用户异常行为最终检测;
 - 步骤 10: 组合通过训练所得出的弱分类器, 输出最终用户行为异常检测结果。
- 用户异常用户行为检测流程如图 4 所示。




图 4 用户异常用电行为检测流程

Fig. 4 Detection process for abnormal electricity consumption behavior of users

3 实验结果与分析

3.1 实验参数

为了对所提方法优越性进行验证,采用南方电网电能信息采集系统采集数据,数据为某省不同地区城网数据,选取 2023 年某日电力用户用电负荷数据,以 15 分钟采集一次为例进行说明,一天 96 次,选出 5 000 户用电数据,其中正常用户 4 920 户,异常电力用户 80 户。算法参数如表 1 所示。

模型的性能需要用相关指标进行全面评估,采用精确率 P 、召回率 R 、准确率 A 、 $F1$ 值和检测时间进行评估。如式(8)~式(11)所示:

$$P = \frac{TP}{TP + FP} \tag{8}$$

$$R = \frac{TP}{TP + FN} \tag{9}$$

$$A = \frac{TP + TN}{TP + TN + FP + FN} \tag{10}$$

$$E_{F1} = \frac{2PR}{P + R} \tag{11}$$

式中: TP 和 FN 分别为正常分类为正常数和错误分

类为异常数; FP 和 TN 分别为异常用户错误分类为正常数和正确分类为异常数。

表 1 算法参数


Tab. 1 Algorithm parameters

算法	参数	数值
随机森林	最大迭代次数	100
	树深度	5
	树深度 5	5
XGBoost	学习率	150
	最小叶子节点样本权重	1
	子节点分裂最小损失	0.1
GBDT	树深度	4
	弱学习器最大个数	60
	子树划分条件	80
改进 K-means	种群规模	30
	最大迭代次数	500
	剑鱼数量占种群规模	30%
	沙丁鱼数量占种群规模	70%
	上下边界	[-100,100]
DTW	控制参数 A	4
	控制参数 ε	0.001
	相似度	0.8

检测时间是用于评估模型速度的所有样本检测时间。

3.2 实验分析

使用改进的 K-means 算法对数据集进行聚类,可以得到数据聚类特征曲线。数据聚类特征曲线如图 5 所示。






图 5 数据聚类特征曲线

Fig. 5 Data clustering characteristic curve

- 1)第 1 类为普通用户,此类用户用电负荷与日常生活习惯紧密相关,白天的用电峰值与家庭活动有关,而夜间用电较为平稳,反映出家庭成员休息时的用电需求;
- 2)第 2 类为无高功率电器的老年用户,此类用户用电负荷总体呈低水平,中午至下午出现高峰,其他时段均维持在较小范围;
- 3)第 3 类是偏好大功率电器的用户,该类用户用电负荷峰值主要为两个时段,上午和下午,上午时间较短,下午时间较长;
- 4)第 4 类为工业用户,此类用户的用电负荷在一天中呈现较高负荷状态;
- 5)第 5 类为工业用户(夜间大功率),这种用户用电负荷终日呈现高负荷状态,夜间负荷峰值较高;
- 6)第 6 类为工作族和老年用户,此类用户的用

电负荷全天出现两个高峰,早上和晚上,晚高于早;

7)第 7 类为大功率电器工作族或非工作族家庭用户,此类用户用电负荷全天保持较高水平,中午出现较长时间负荷高峰;

8)第 8 类为无较多大功率电器的工作族和老人用户,此类用户用电负荷全天保持平稳状态,上午和晚上出现负荷峰值。

利用聚类手段对用户用电行为进行分析和分类,是一种高效的数据挖掘技术,可以将具有相似用电模式的用户分类为同一类别,提高分类管理效率。

通过改进的 DTW 距离对负载曲线的相似性进行度量。从负载曲线 1 中分别选择正常数据 A、B 和异常用电数据 C 和 D,不同数据相似度检测结果如表 2 所示。

表 2 不同数据相速度检测结果
Tab. 2 Comparison of detection results of different models

负荷特征曲线	数据 A 相似度	数据 B 相似度	数据 C 相似度	数据 D 相似度
1	0.826 2	0.803 6	0.486 7	0.567 5
2	0.615 5	0.586 5	0.462 5	0.439 9
3	0.721 2	0.683 2	0.603 2	0.751 2
4	0.198 5	0.199 2	0.202 1	0.226 4
5	0.220 3	0.232 0	0.300 5	0.560 5
6	0.510 2	0.541 2	0.564 2	0.666 2
7	0.431 2	0.432 8	0.623 7	0.608 9
8	0.730 8	0.737 1	0.417 8	0.478 5

由表 2 的数据可以看到用户用电行为与不同负载特性曲线的相似度比较。用户 A 和 B 的用电数据与负载特征曲线 1 的相似度分别为 0.826 2 和 0.803 6,与曲线 2-8 相似度均在 0.8 以下,说明 A 和 B 为符合 1 类,判定为正常用户。用户 C 和 D 的用电数据与负载特征曲线 1 的相似度分别为 0.486 7 和 0.567 5,与曲线 2-8 相似度均在 0.8 以下,判定为异常用户,对其还需进一步检测。通过初步筛选得到的异常用电行为用户为 150 户,经查证包含 80 户异常用电用户。综上所述,通过比较用户的用电数据与不同负载特征曲线的相似度,不仅能够识别用户的电力使用习惯,而且能够利用这些信息来辅助判断用户是否存在异常用电等不当用电行为。

在实施模型训练和测试过程中,选择将 150 户初始筛选异常数据和 350 户正常数据组合成混合数

数据集,模拟实际环境中的数据分布情况。将数据集按 7:3 的比例分成训练集和测试集。为了验证本文集成学习模型的有效性,与单一模型的随机森林、XGBoost、GBDT 进行对比分析,融合模型和单一模型的异常检测结果如图 6 所示。融合模型和单一模型异常检测结果如表 3 所示。




图 6 融合模型和单一模型异常检测效果
Fig. 6 Anomaly detection effects between fusion model and single model

表 3 融合模型单一模型异常检测结果
Tab. 3 Comparison of calculation results of different models

模型	$P/\%$	$R/\%$	$A/\%$	F1 值/ $\%$
随机森林	96.80	96.03	94.00	96.41
XGBoost	96.00	95.24	92.66	95.62
GBDT	95.20	94.44	91.33	94.82
本文融合模型	99.21	100.00%	99.33	99.60

由图 6 和表 3 可以看出,文章融合模型把 1 户

异常用户检测为正常,随机森林模型把 4 户异常用户检测为正常和 5 户正常检测为异常,XGBoost 模型把 5 户异常用户检测为正常和 6 户正常检测为异常,GBDT 模型把 6 户异常用户检测为正常和 7 户正常检测为异常。文章融合模型在准确率、召回率、准确率和 F1 值多项指标中具有最优性能,精确率 99.21%,召回率 100.00%,准确率 99.33%,F1 值 99.60%。与随机森林、XGBoost 和 GBDT 模型相比,本文融合模型精确率分别提高 2.49%、3.34% 和 4.21%,召回率分别提高 4.13%、5.00% 和 5.89%,准确率分别提高 5.67%、7.20% 和 8.76%。F1 值分别提高 3.31%、4.16%、5.04%。上述比较表明,Stacking 集成学习模型可以有效地提高单个模型的检测性能,从而更好地检测用户的异常用电行为。

为了进一步验证文章用户异常用电行为检测方法的优越性,将文章方法与文献[9]的 CNN-GA-SVM 模型、文献[10]结合改进的 K-medoids 聚类 and SVM 模型、文献[11]的 Stacking 集成模型和文献[22]的改进 SVM 模型进行对比分析。不同模型检测结果如表 4 所示。

表 4 不同模型检测结果
Tab. 4 Comparison of calculation results of different models

模型	$P/\%$	$R/\%$	$A/\%$	F1 值/ $\%$	检测时间/s
文献[9]	99.12	95.77	95.20	97.42	20.32
文献[10]	99.25	93.66	93.33	96.37	9.12
文献[11]	99.28	97.18	96.66	98.22	30.32
文献[22]	98.97	95.17	94.40	97.03	21.00
本文方法	99.93	100.00	99.93	99.96	8.32

由表 4 可以看出,文章方法在准确率、召回率、准确率和 F1 值多个指标中具有最优性能,精确率为 99.93%,召回率为 100.00%,准确率为 99.93%,F1 值为 99.96%,测量时间为 8.32 s。与文献[9-11, 22]相比,本文方法的精确率分别提高了 0.82%、0.69%、0.65%、0.97%,召回率分别提高了 4.42%、6.77%、2.90%、5.08%,准确率分别提高了 4.97%、7.07%、3.45%、5.86%。F1 值分别提高 2.61%、3.73%、1.77%、3.02%,检测时间分别下降 59.06%、8.77%、72.56%、60.38%。通过上述比较分析,进一步说明文中用户异常检测方法的优势,可以为电力企业缩小实际排查范围,提高工作效率。

4 结论

文章结合 K-means 算法、改进的时间动态弯曲算法和 Stacking 集成学习算法用于用户异常用电行为检测。结果表明,通过多技术的有效结合,所提方法不仅提升了用户异常用电行为检测的准确率,也大幅降低了检测所需时间,极大地提高了检测系统响应速度。检测准确率为 99.93%,检测时间为 8.32 s。与文献[9-11,22]相比,文中方法准确率分别提高了 4.97%、7.07%、3.45%、5.86%。检测时间分别降低 59.06%、8.77%、72.56%、60.38%。为电网安全提供了有力支持。文章仅分析负荷数据,后期可以结合个人信用、用电环境等因素进行综合分析,进一步提高检测性能。

参考文献

- [1] 薛阳,张蓬鹤,杨艺宁,等.基于线损协方差分析的群体性固定比例窃电行为检测方法[J].电力系统自动化,2022,46(13):112-120.
Xue Yang, Zhang Penghe, Yang Yining, et al. A detection method for collective fixed proportion electricity theft behavior based on line loss covariance analysis[J]. Automation of Electric Power Systems, 2022, 46(13): 112-120.
- [2] 张宇娇,李宏松,郭垚,等.电缆支架全生命周期碳排放计算与分析[J].高压电器,2024,60(4):40-48.
Zhang Yujiao, Li Hongsong, Guo Yao, et al. Calculation and analysis of carbon emission of cable bracket during its whole life cycle[J]. High Voltage Apparatus, 2024, 60(4): 40-48.
- [3] 邵振,邹晓松,袁旭峰,等.基于改进多目标粒子群优化算法的配电网削峰填谷优化[J].科学技术与工程,2020,20(10):3984-3989.
Shao Zhen, Zou Xiaosong, Yuan Xufeng, et al. Optimization of peak load shifting in distribution network based on improved MOPSO algorithm[J]. Science Technology and Engineering, 2020, 20(10): 3984-3989.
- [4] 孙睿晨,董坤,赵剑锋,等.基于递进式模型结构和时间信息嵌入的非侵入式负荷分解[J].智慧电力,2024,52(2):55-62,70.
Sun Ruichen, Dong Kun, Zhao Jianfeng, et al. Non-intrusive load decomposition based on progressive model structure and temporal information embedding[J]. Smart Power, 2024, 52(2): 55-62, 70.
- [5] 张坤,张健辉,杜文静,等.基于线性回归的精准识别窃电用户的研究[J].电子设计工程,2023,31(7):51-55.
Zhang Kun, Zhang Jianhui, Du Wenjing, et al. Research on accurate identification of electricity thief users based on linear regression[J]. Electronic Design Engineering, 2023, 31(7): 51-55.
- [6] 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 fusion of multiple heterogeneous learners and Stacking ensemble learning[J]. Automation of Electric Power Systems, 2022, 46(24): 178-186.
- [7] 胡一伟,刘珊,黄浩.基于 ARIMA 和递归贝叶斯的窃电用户识别算法[J].电测与仪表,2022,59(6):196-200.
Hu Yiwei, Liu Shan, Huang Hao. Electricity theft user identification algorithm based on ARIMA and recursive Bayes[J]. Electrical Measurement & Instrumentation, 2022, 59(6): 196-200.
- [8] 秦志沁,韩玉环,张毅,等.基于 VMD 分解和随机矩阵理论的异常用电状态检测[J].太原理工大学学报,2024,55(1):66-72.
Qin Zhiqin, Han Yuhuan, Zhang Yi, et al. Abnormal power consumption state detection based on VMD decomposition and random matrix theory[J]. Journal of Taiyuan University of Technology, 2024, 55(1): 66-72.
- [9] 徐瑶,李栓,韩英华.基于 CNN-GS-SVM 的用户异常用电行为检测[J].控制工程,2021,28(10):1989-1997.
Xu Yao, Li Shuan, Han Yinghua. User abnormal electricity consumption behavior detection based on CNN-GS-SVM [J]. Control Engineering, 2021, 28(10): 1989-1997.
- [10] 胡聪,徐敏,洪德华,等.基于改进 K-medoids 聚类 and SVM 的异常用电模式在线检测方法[J].国外电子测量技术,2022,41(2):53-59.
Hu Cong, Xu Min, Hong Dehua, et al. An online detection method for abnormal electricity consumption patterns based on improved K-medoids clustering and SVM[J]. Foreign Electronic Measurement Technology, 2022, 41(2): 53-59.
- [11] 程超鹏,彭显刚,曾勇斌,等.相异模型下 Stacking 集成结构的异常用电用户识别方法[J].电网技术,2021,45(12):4828-4836.
Cheng Chaopeng, Peng Xiangang, Zeng Yongbin, et al. Abnormal electricity user identification method for Stacking integrated structure under different models[J]. Power System Technology, 2021, 45(12): 4828-4836.
- [12] 钟小强,陈杰,蒋敏敏,等.基于深度学习的台区线损分析方法[J].电网技术,2020,44(2):769-774.
Zhong Xiaoqiang, Chen Jie, Jiang Minmin, et al. Line loss analysis method in substation area based on deep learning[J]. Power System Technology, 2020, 44(2): 769-774.
- [13] 张智泉,陈晓杰,符杨,等.基于核仁聚类估计和数据

- 驱动分布鲁棒优化的海量异构产消者联盟能量管理策略[J]. 电力系统保护与控制, 2024, 52(7): 98-114.
- Zhang Zhiqian, Chen Xiaojie, Fu Yang, et al. Energy management strategy for massive heterogeneous prosumers alliance based on nucleolar clustering estimation and data-driven distributionally robust optimization[J]. Power System Protection and Control, 2024, 52(7): 98-114.
- [14] 汪司珂, 明东岳, 郭雨, 等. 基于 AQPSO-LSSVM 的电网线损率预测模型[J]. 计算技术与自动化, 2020, 39(4): 75-80.
- Wang Sike, Ming Dongyue, Guo Yu, et al. Power grid line loss rate prediction model based on AQPSO-LSSVM[J]. Computing Technology and Automation, 2020, 39(4): 75-80.
- [15] 唐辉, 刘晓波, 韩祥民, 等. 基于混沌剑鱼算法的 K-means 算法[J]. 智能计算机与应用, 2022, 12(1): 69-73, 79.
- Tang Hui, Liu Xiaobo, Han Xiangmin, et al. The K-means algorithm based on chaotic swordfish algorithm[J]. Intelligent Computers and Applications, 2022, 12(1): 69-73, 79.
- [16] 闫重熙, 陈皓. 基于改进天牛须搜索算法优化 LSSVM 短期电力负荷预测方法研究[J]. 电测与仪表, 2020, 57(6): 6-11, 18.
- Yan Chongxi, Chen Hao. Research on LSSVM short-term power load forecasting method based on improved tianniu whisker search algorithm[J]. Electrical measurement & instrumentation, 2020, 57(6): 6-11, 18.
- [17] 黄子蒙, 余娟, 向明旭, 等. 基于改进动态时间弯曲的 PMU 频率异常检测及类型识别[J]. 电力系统自动化, 2022, 46(24): 104-112.
- Huang Zimeng, Yu Juan, Xiang Mingxu, et al. PMU frequency anomaly detection and type recognition based on improved dynamic time bending[J]. Automation of Electric Power Systems, 2022, 46(24): 104-112.
- [18] 童晓阳, 杨明杰, 张广骁. 基于改进 DTW 的行波波形相似性的高压直流输电线路保护方案[J]. 中国电机工程学报, 2020, 40(12): 3878-3887.
- Tong Xiaoyang, Yang Mingjie, Zhang Guangxiao. A high voltage direct current transmission line protection scheme based on improved DTW for traveling wave waveform similarity[J]. Proceedings of the CSEE, 2020, 40(12): 3878-3887.
- [19] 江永鑫, 陈丽安, 郭梦倩, 等. 基于改进 CEEMD 和 RF 的低压串联故障电弧识别方法[J]. 电力系统保护与控制, 2024, 52(1): 97-108.
- Jiang Yongxin, Chen Li'an, Guo Mengqian, et al. Identification method of low voltage series fault arc based on improved CEEMD decomposition and RF[J]. Power System Protection and Control, 2024, 52(1): 97-108.
- [20] 赵庆明. 基于近邻传播算法和随机森林回归模型的台区线损率计算方法[J]. 电力系统及其自动化学报, 2020, 32(9): 94-98.
- Zhao Qingming. Calculation method of line loss rate in substation area based on the nearest neighbor propagation algorithm and random forest regression model[J]. Proceedings of the CSU-EPSC, 2020, 32(9): 94-98.
- [21] 陆旦宏, 范文尧, 杨婷, 等. 基于生成对抗 Transformer 的电力负荷数据异常检测[J]. 电力工程技术, 2024, 43(1): 157-164.
- Lu Danhong, Fan Wenyao, Yang Ting, et al. Anomaly detection of power load data based on Transformer and generative adversarial networks[J]. Electric Power Engineering Technology, 2024, 43(1): 157-164.
- [22] 张丽娟, 保富. 基于改进 SVM 的电力用户异常用电行为检测方法研究[J]. 电测与仪表, 2022, 59(12): 163-168.
- Zhang Lijuan, Bao Fu. Research on abnormal electricity consumption behavior detection method for power users based on improved SVM[J]. Electrical Measurement & Instrumentation, 2022, 59(12): 163-168.

收稿日期: 2024-05-22; 修回日期: 2024-07-29

作者简介:

钟磊(1987—), 男, 通信作者, 工程师, 研究方向为计量自动化与电能量数据应用。E-mail: wumin19824@163.com

姜雪娇(1985—) 女, 高级工程师, 研究方向为计量自动化与电能量数据管理。E-mail: jiangxj195@163.com

吴海杰(1988—) 男, 硕士, 工程师, 研究方向为智能测量。E-mail: wuhaij82@163.com

吴民(1982—) 男, 工程师, 研究方向为计量自动化、通信通道。E-mail: wumin19824@163.com

孙延松(1972—) 男, 高级工程师, 研究方向为电能计量、计量自动化。E-mail: sysong30@163.com

徐佳隆(1995—) 男, 助理工程师, 研究方向为营销计量与电能量数据应用。E-mail: xjial05@163.com

(编辑 王克祥)