

基于边缘计算的用户异常负荷识别方法^{*}

周 玉¹ 张 震¹ 马云龙² 李 悦¹ 高 凡¹ 韦 喆¹

(1. 国网江苏省电力有限公司营销服务中心 南京 210028; 2. 江苏省电力有限公司 南京 210000)

摘 要:针对未知家电负荷背景下基于智能电表采样数据进行异常负荷识别问题,以电动车入户充电负荷为出发点,提出了一种基于边缘计算的用户异常负荷识别方法。首先通过 Boruta-SHAP 算法对非侵入式负荷数据的 14 种特征进行排序筛选,得到在秒级负荷数据下的辨识效果最佳的特征子集;然后采用改进的非平行支持向量机(v-non parallel support vector machine, v-NPSVM)模型进行异常负荷识别模型的训练;最后结合边缘计算技术将算法部署到边缘计算平台上,实现对典型电动车充电负荷的识别。实验基于低压台区中智能电表获取的真实负荷数据进行验证,并进一步对数据进行降频处理以验证更低频数据源下方法的有效性,实验结果表明针对降频后的异常负荷识别的正确辨识率仍在 90% 以上,证明了在未知家电负荷背景下方法具有较好的适用性和准确性。

关键词:非侵入式负荷识别;边缘计算;v-NPSVM;异常负荷;电动车入户充电

中图分类号: TP181; TM714 **文献标识码:** A **国家标准学科分类代码:** 470.40

User abnormal load identification method based on edge computing

Zhou Yu¹ Zhang Zhen¹ Ma Yunlong² Li Yue¹ Gao Fan¹ Wei Zhe¹

(1. State Grad Jiangsu Marketing Sever Center, Nanjing 210028, China;

2. Jiangsu Electric Power Co., Ltd., Nanjing 210000, China)

Abstract: In order to solve the problem of abnormal load identification based on smart meter sampling data in the context of unknown household appliance load, this paper proposes a user abnormal load identification method based on edge computing based on the charging load of electric vehicles. Firstly, the Boruta-SHAP algorithm was used to sort and screen 14 features of the non-intrusive load data, and the subset of features with the best identification effect under the second-level load data was obtained. Then, the v-non parallel support vector machine (v-NPSVM) model was used to train the abnormal load recognition model. Finally, the algorithm is deployed on the edge computing platform combined with edge computing technology to realize the identification of typical electric vehicle charging loads. The experimental results show that the correct identification rate of abnormal load identification after frequency reduction is still more than 90%, which proves that the proposed method has good applicability and accuracy in the context of unknown household appliance load.

Keywords: non-intrusive load identification; edge computing; v-NPSVM; abnormal load; user charging for electric vehicles

0 引 言

自智慧城市概念的提出以来,持续引发了全球智慧城市的发展热潮,居民区异常负荷监测的要求也随之不断提高^[1]。导致产生异常负荷的事件之一的电动车入户充电现象由于近年来电能交通工具的发展,在居民楼中屡见不

鲜。截至 2022 年底,据不完全统计我国目前的电动车总数接近 3.5 亿辆,平均 4 人/辆,电动车的出现无疑为我们带来了便利,但随之而来的问题也有很多。其中电动自行车引发火灾的事件数量不断上升,电动自行车因整车线路故障引发火灾的事故占 90% 以上;停放充电时引发火灾的事故占 80% 以上;在 20:00 至次日 5:00 的火灾发生率

收稿日期:2023-10-13

^{*} 基金项目:国家电网科技项目(J2022136)资助

占67%左右^[2]。目前针对居民楼火灾隐患的排查措施主要是依靠人工巡检,这种方法往往需要耗费大量人力且效率较低^[3]。而随着物联网技术的发展,另一种将居民楼内的传感器智能控制终端互联,实现智能化火灾监测的方法也应运而生。但由于服务器算力以及实际运营成本的有限性,如何在实际场景中利用相关设备有效的检测出如电动车入户充电一类现象逐渐成为亟需解决的问题。近年来,随着边缘计算技术的不断发展,该技术被应用于如消防安全^[4]、虚拟现实^[5]、智能家居^[6]等领域。边缘计算是一种将数据处理和计算能力尽可能地放置在接近数据源的边缘设备或边缘节点上的模型,而不是依赖传统的云计算模式。边缘计算的主要优势之一是实时性更高,由于数据的处理和分析发生在接近数据源的边缘设备上,可以减少数据从设备到云服务器的传输延迟。这对于需要快速响应和低延迟的应用非常重要,例如无人驾驶车辆需要实时感知和决策^[7]。另一个重要的优势是边缘计算可以减少能耗。传统的云计算模型通常需要大量的数据传输和集中式的数据处理,这可能会导致大量的能源消耗。边缘计算可以在本地设备上进行部分计算和处理,减少了对云服务器的依赖,从而降低了整体的能耗。总体而言,边缘计算为许多应用场景提供了一种更加高效和可靠的计算模型。

非侵入式负荷监测技术^[8](non-intrusive load monitoring, NILM)往往与负荷识别问题密不可分^[9-10]。文献^[11]提出一种基于边缘计算的电动车入户充电检测方法,利用电梯内监控结合图像识别技术完成对电动车入户这一过程的监测。文献^[12]提出了一种利用电动自行车恒压充电阶段在有功功率和无功功率中所表现的局部特征,通过事件检测、状态转换移除、Savitzky-Golay滤波与序列匹配相结合的方法实现电动车负荷的识别。这种方法虽然解决了实际场景中采样频率低的问题,且可以在数据标签未知的情况下实现负荷识别,但是对数据质量以及电池种类要求较高,在实际应用层面存在一定限制。文献^[13]基于一分类支持向量机的方法,通过Fisher计分法选择特征作为输入来进行电动车的负荷辨识,并结合了增量学习的步骤来提高分类器性能,但是要求训练集与测试集中异常负荷和家电样本所占比例一致,在实际场景中无法满足。且上述研究都建立在高频采样的基础上,最低要求采样频率在几百赫兹^[14],而在实际场景中,大多数NILM数据来源于智能电表,采样频率远远达不到以上研究的最低要求。目前国内对于基于秒级采样频率的NILM方法研究较少,文献^[15]提取家电稳态电流作为特征输入,利用差分进化算法计算家电的开启时间系数,从而实现负荷识别,但是对小功率电器识别精度不高。文献^[16]提出了基于多特征序列融合的负荷辨识方法,但是家电功率变化规律相近时精度不高。

本文基于实际应用场景提出了一种基于边缘计算的用户异常负荷识别方法。该方法在低采样频率实测数据的基础上进行研究,首先采用Boruta-SHAP算法^[17]对特征重要性进行计算,筛选出在低采样率情况下辨识度更优的特征子集。接着采用改进的非平行支持向量机算法^[18-19](v-non parallel support vector machine, v-NPSVM)对负荷数据进行训练,得到负荷识别模型。进行前期工作后,结合边缘计算技术与云计算技术建立一个边缘计算平台,在边缘节点上进行对采集数据的预处理并上传云平台,由云平台利用采集数据完成对判别模型的训练,并将训练好的判别模型下发边缘节点,在边缘节点实现对异常负荷的识别并将结果发送给监测端再进行进一步处理。在实验阶段采用不同用电背景的数据源对算法模型进行验证,并对1/5 Hz的智能电表数据再次降频,证明本文方法可以对秒级数据实现用户异常负荷的识别。

1 基于边缘计算的电动车充电负荷识别方法概述

本文建立了一个边缘计算平台,将边缘计算和云计算相结合,具体架构如图1所示。在该平台上,边缘节点从智能电表侧收集用户的非侵入式负荷数据,并将这些数据进行预处理后上传到云平台。云平台利用数据进行判别模型的训练,生成判别模型后将模型打包下发给边缘节点。边缘节点利用建立好的模型对新采集的数据进行预处理和电动车充电负荷识别,最终识别结果送回云平台,由云平台再进行下一步处理,如应用管理、数据储存等。

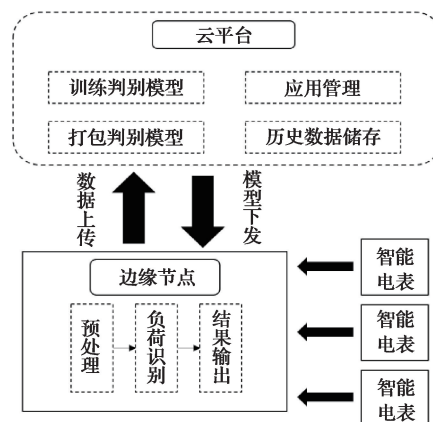


图1 边缘计算平台架构

Fig. 1 Edge computing platform architecture

在云平台中的算法模型通过如下步骤实现对负荷数据的识别:1)预处理,对边缘节点上传的负荷数据中由于不可靠通信造成的缺失值进行删除,然后对数据进行归一化、滤波处理;2)初次判别,将预处理后数据输入训练好的算法模型中进行初次判别,本文使用v-NPSVM算法进行识别模型训练;3)二次判别,在进行初次判别后对判别结果进行防抖动处理,滤波真实环境中因难以去除的噪声导

致的判别错误,得到最终判别结果;4)输出结果到监测端,当检测到电动车充电负荷时发出报警信号,并输出充电的起始时刻与终止时刻。

2 秒级采集频率负荷数据下的特征选择

2.1 电动自行车电池负荷分析

与其他电器的电流波形相比,电动自行车的充电电流波形非线性程度较大,畸变严重,瞬时功率峰值较高。在启动时,它还会产生短时脉冲电流和延迟时间。为了更具体地反映电动自行车电池的负荷特性,本文选取了14个负荷特征作为初始特征集,包括有功功率、无功功率、电流、电压、各次(1~9)谐波和电流畸变率(THD)。从负荷特性的角度来看,通常主要关注谐波次数及其对应的幅值。然而,现有研究表明,大多数负荷在运行时产生的偶次谐波幅值较小^[20],区分度不高。相反,奇次谐波幅值通常更显著,因此本文选择了奇次谐波进行详细观察分析。

由于国内智能电表目前采样频率较低,导致利用智能电表采集的负荷特征无法难以准确辨识出异常负荷。针对部分特征在秒级数据下的分辨率不佳的问题,本文采用Boruta-SHAP算法对14个负荷特征进行筛选排序,得到在秒级数据下辨识度更佳的特征子集。

2.2 Boruta-SHAP 特征选择方法

Boruta 算法^[21-22]是一种基于随机森林的特征选择算法,用于确定数据集中最重要的特征。核心思想是通过比较原始特征和随机生成的“影子”特征来判断特征的重要性。令 \mathbf{X} 表示输入的特征矩阵, \mathbf{y} 表示目标变量向量, Boruta 算法的步骤如下。

- 1)进行特征的重要性初始化,对于每个特征 x_i ,初始化它的重要性得分为0。
- 2)创建影子特征,使用随机排列的特征矩阵 \mathbf{X} ,生成与原始特征一样的影子特征矩阵 \mathbf{X}' 。
- 3)训练随机森林模型,使用特征矩阵 \mathbf{X} 和目标变量 \mathbf{y} 训练一个随机森林模型,并计算每个特征的重要性得分。
- 4)比较特征重要性,对于每个特征 x_i ,通过比较其重要性得分与影子特征矩阵中对应特征的重要性得分,使用统计检验来判断特征是否显著。
- 5)更新特征重要性得分,对于显著的特征,将其重要性得分增加,并重复步骤3)~4)直到收敛。

SHAP 算法是一种用于解释机器学习模型预测结果的方法,基于博弈论的概念,计算每个特征对预测结果的贡献。令 f 表示训练好的模型, x 表示输入样本。SHAP 值可以定义为:

$$SHAP(x_i) = \sum_{S \subseteq N \setminus \{i\}} \frac{|S|! (N - |S| - 1)!}{N!} [f(S \cup \{i\}) - f(S)] \quad (1)$$

式中: N 是特征的总数; S 是特征子集; $f(S)$ 是模型在子集 S 上的预测结果。SHAP 值表示特征 x_i 相对于一个参考特征集的贡献。正的 SHAP 值表示特征对结果的正

向影响,负的 SHAP 值表示特征对结果的负向影响。

Boruta-SHAP 算法结合了 Boruta 和 SHAP 算法,用于对特征的选择。首先,使用 Boruta 算法进行特征选择,在计算特征与影子特征的重要性时,采用 SHAP 值来代替常规的决策树的不纯度(gini impurity),通过比较特征的重要性得分来判断其显著性。如果一个特征的 SHAP 值显著大于随机生成的影子特征的 SHAP 值,那么可以认为该特征是显著重要的。这种判断是通过二项检验和 Bonferroni 校正完成的。

Boruta-SHAP 算法提供了一个综合的方法,既能选择最重要的特征,又能解释这些特征对于预测结果的影响。这样的组合方法能够提供更全面的特征选择和模型解释结果,增强了模型的可解释性和可靠性。

3 基于 ν -NPSVM 算法的电动车充电负荷识别模型

由于在实际应用中边缘计算可以提供更快速、安全、隐私保护的数据处理和决策能力,降低网络延迟和带宽需求,并支持离线和分布式计算环境。但边缘设备的计算资源有限,算法需要具备低计算复杂度,才能够在边缘设备上高效地执行,故本文选择改进的非平行支持向量机模型,在避免过多的计算和存储需求的前提下,实现对异常负荷的精准识别,以适应边缘设备的资源限制。

NPSVM 算法是在传统的单目标函数支持向量机基础上提出的,相较于采用双目标函数的孪生支持向量机, NPSVM 引入传统支持向量机“软间隔”的思想^[23-24],并且改善了 TWSVM(twin support vector machines)稀疏性较差的问题。 ν -NPSVM 则是采用参数 ν 来替代现有支持向量机的参数 C ,能够有效控制支持向量的数量,在保证较高准确率和时间复杂度的前提下有效改善暂态稳定评估性能。

对于二分类问题, ν -NPSVM 需要寻找两个非平行的超平面:

$$(\mathbf{w}_+ \cdot \mathbf{x}) + b_+ = 0, (\mathbf{w}_- \cdot \mathbf{x}) + b_- = 0 \quad (2)$$

使得每个超平面都接近于一类数据点,并尽可能远离其他类数据点。将每个超平面可以描述为一个凸性二次规划问题^[25]。通过求解如下两对二次规划问题得到这两个超平面。

$$\begin{cases} \min_{\mathbf{w}_+, b_+, \rho_+, \epsilon_+, \eta_+, \xi_+} \frac{1}{2} \|\mathbf{w}_+\|^2 + C_1 \left(v_1 \epsilon_+ + \frac{1}{p} \sum_{i=1}^p (\eta_i + \eta_i^*) \right) + \left(-v_2 \rho_+ + \frac{1}{q} \sum_{j=p+1}^{p+q} \xi_j \right), \\ \text{s. t. } (\mathbf{w}_+ \cdot \mathbf{x}_i) + b_+ \leq \epsilon_+ + \eta_i, i = 1, \dots, p, \\ -(\mathbf{w}_+ \cdot \mathbf{x}_i) - b_+ \leq \epsilon_+ + \eta_i^*, i = 1, \dots, p, \\ \eta_i, \eta_i^* \geq 0, i = 1, \dots, p, \\ (\mathbf{w}_+ \cdot \mathbf{x}_j) + b_+ \leq -\rho_+ + \xi_j, j = p+1, \dots, p+q, \\ \xi_j \geq 0, j = p+1, \dots, p+q, \rho_+ \geq 0, \epsilon_+ \geq 0 \end{cases} \quad (3)$$

$$\left\{ \begin{array}{l} \min_{w_+, b_+, v_+, \epsilon_+, \eta_+, \xi_-} \frac{1}{2} \|w_+ + \|^2 + C_3 \left(v_3 \epsilon_- + \right. \\ \left. \frac{1}{q} \sum_{i=p+1}^{p+q} (\eta_i + \eta_i^*) \right) + \left(-v_4 \rho_- + \frac{1}{p} \sum_{j=1}^p \xi_j \right), \\ \text{s. t. } (w_- \cdot x_i) + b_- \leq \epsilon_- + \eta_i, i = p+1, \dots, p+q, \\ -(w_- \cdot x_i) - b_- \leq \epsilon_- + \eta_i^*, i = p+1, \dots, p+q, \\ \eta_i, \eta_i^* \geq 0, i = p+1, \dots, p+q, \\ (w_- \cdot x_j) + b_- \leq -\rho_- - \xi_j, j = 1, \dots, p, \\ \xi_j \geq 0, j = 1, \dots, p, \rho_- \geq 0, \epsilon_- \geq 0 \end{array} \right. \quad (4)$$

式中：对于 x_i ，当 $i=1, \dots, p$ 时为正类点，当 $i=p+1, \dots, p+q$ 时为负类点； $C_i \geq 0 (i=1, \dots, 4)$ 为惩罚参数； ξ_+ 、 ξ_- 为适当维数的松弛向量； $\eta_+^{(*)}$ 、 $\eta_-^{(*)}$ 为适当维数的向量； $v_i (i=1, 2, 3, 4)$ 分别为控制正稀疏度和负稀疏度的参数。

相对于传统支持向量机，v-NPSVM 并不是把所有的样本点都出现一个约束条件里，而是与目标函数的样本点相对应的另一类样本点放在了约束条件里。这样原本一个大的求解方式变成了两个小的求解模型，极大地提高了训练速度，而且将其需要指定的参数替换为参数 v_i ，可以有效地控制支持向量的数量。

4 实验分析

4.1 数据采集

本文数据来源于江苏省低压台区用户实验测试数据，智能电表最高采样频率为 1/5 Hz，充电电池参数为 60 V/20 Ah、48 V/20 Ah、48 V/24 Ah。首先使用 Boruta-SHAP 算法对实测数进行特征选取，得到辨识度更高的特征子集。后续的负荷识别算法实验包括为两个阶段，第 1 个阶段选取含有电动车电池充电数据 4 户真实用户，在已知家电种类以及家电运行状态的情况下，划分训练集与测试集，验证 Boruta-SHAP 算法与 v-NPSVM 算法的识别正确率；在第 2 阶段选取与第 1 阶段实验用户不同且含有电动车电池充电数据 3 户真实用户作为数据来源，在未知家电背景的情况下以充电事件检测的角度，验证整体识别方法的正确率与普适性。

4.2 特征选择方法验证

为验证特征选择方法的有效性，首先采集已知家电背景的 4 户用户负荷数据构建训练集、测试集。。从电气特性的角度来看，家电可以分为 3 大类，电感性电器、电容性电器和电阻性电器，本文选择覆盖这些常见电器种类的用户作为数据源。第 1 阶段已知家电背景数据包括了 4 个用户的 5 日数据，每天的时间跨度为 8:30 ~ 17:30。电池的投切是人为控制的，投切次数为每天 9 次，共计 554 充电样本。电池的投切时刻表与家电种类如表 1 所示。

表 1 测试居民部分家电信息与电池投切时刻

Table 1 Testing the partial household appliance information and battery switching schedule

家电种类	额定功率/W	电池投切时间
冰箱	200	8:30 开 14:00 关
微波炉	600	9:00 关 14:30 开
开水壶	1 500	9:30 开 15:30 关
壁挂空调	800	10:00 关 16:00 开
洗衣机	800	10:30 开 16:30 关
电饭煲	750	11:00 关 17:00 开
电视机	250	11:30 开 17:30 关
豆浆机	700	12:00 关
立式空调	1 500	12:30 开
电磁炉	2 100	13:00 关
消毒柜	290	13:30 开

基于 Boruta-SHAP 算法对实测数据进行特征重要性度量。从 554 个含电动车电池充电样本随机选取其中 100 个含有电动车充电事件的样本进行测试，初始特征集由有功功率、无功功率、电流、电压、各次 (1~9) 谐波和 THD 的 14 个特征组成。本位设置的显著性水平为 0.05，特征得到如果二项检验校正结果值大于显著性水平，则接受原假设，拒绝备择假设，表示该特征在统计上不如最大阴影，反之则拒绝原假设，接受备择假设。根据 Boruta-SHAP 的计算结果，各个特征的重要性箱线图分布情况如图 2 所示。将各个特征重要性计算结果按降序排列的结果如图 3 所示，其中特征 U 、 X_4 被标记为不重要特征， X_8 特征被标记为待定。

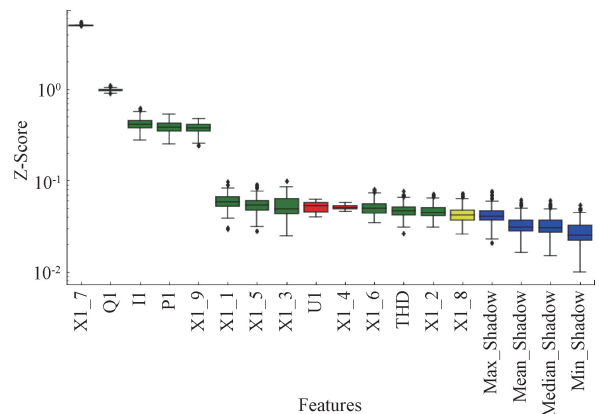


图 2 各个特征重要性箱线图

Fig. 2 Box plot of importance scores for each feature

根据 Boruta-SHAP 算法结果，将特征集划分为 3 个特征子集 $Z1$ 、 $Z2$ 、 $Z3$ 。

$Z1$: 有功功率、无功功率、电流、电流畸变率以及 1、2、3、5、7、9 次谐波。

$Z2$: 有功功率、无功功率、电流、电流畸变率以及 1、2、

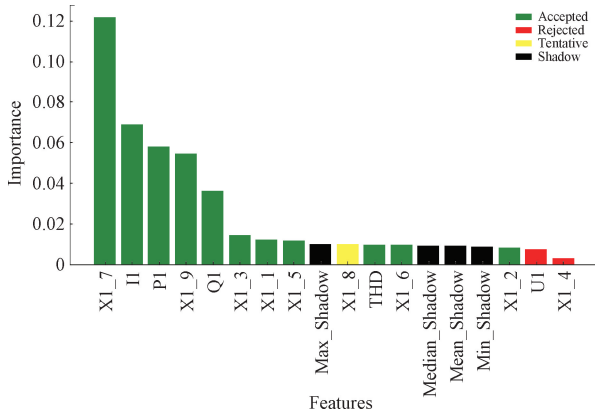


图3 特征重要性选择结果

Fig. 3 Feature importance selection results

3、5、7、8、9次谐波。

Z3:电压、有功功率、无功功率、电流、电流畸变率以及1、2、3、4、5、7、8、9次谐波。

分别以Z1、Z2、Z3作为输入特征,采用已知家电背景数据利用支持向量机进行特征辨识。

结果如图4所示,其中采用Z1特征子集时辨识正确率最高,故将8次谐波剔除,最终选择的特征子集结果为有功功率、无功功率、电流、THD以及1、2、3、5、7、9次谐波。

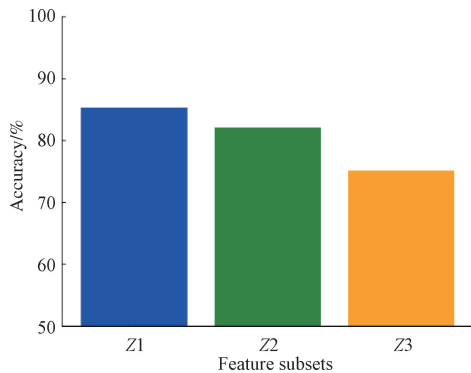


图4 各特征子集作为输入的辨识结果

Fig. 4 Recognition results with various feature subsets as input

4.3 已知家电背景实验

确定特征子集后,利用已知家电背景数据训练NPSVM辨识模型。本文采用4个用户负荷数据的其中5d数据作为NPSVM的训练集输入,对支持向量机中的参数C以及v进行寻优并进行分类器模型训练,共计58122个数据点,按照投切事件划分为311个含电动车电池充电样本。测试集则采用相同用户不同日期共计5天的数据,根据投切事件可划分为243个含电动车电池充电样本。其中惩罚参数 $c_i(i=1,3)$ 以及 $v_i(i=1,2,3,4)$ 利用网格搜索法分别在(0,10]、(0,1]内进行参数寻优。将识别正确

率作为目标函数,目标函数值随着迭代次数的变化趋势如图5所示。

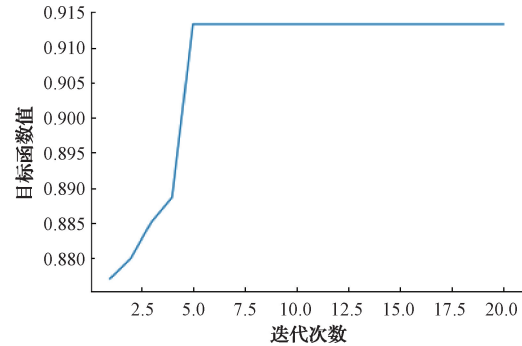


图5 v-NPSVM目标函数值变化情况

Fig. 5 Changes in the objective function values of v-NPSVM

得到最优的参数组合后,使用测试集数据对训练好的v-NPSVM模型进行验证,正确率结果如图6所示(虚线)。根据结果可知,经过模型初次判别后正确率未达到理想效果,这是由于实测数据中存在部分难以去除的噪声导致的。在实际应用中,往往将电动车入户充电视为一段时间内连续发生的事件,而不是由离散的点组成的,故在数据经过分类器判别后加入防抖动机制,只有当超过连续阈值M个数据点时才认为电池充电事件发生。加入防抖动机制进行二次判别后正确率结果如图6所示(实线),可以看到在经历防抖动机制二次判别后识别正确率得到明显提升,总识别正确率由85.443%提升到了90.31%。

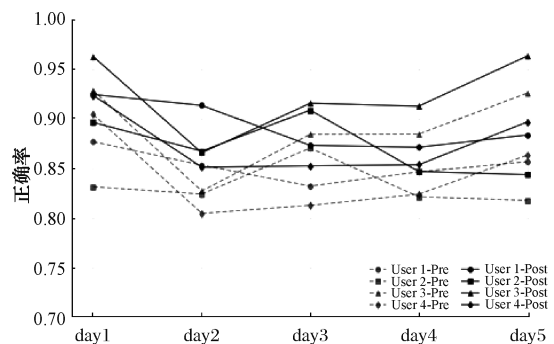


图6 加入防抖动机制前后识别正确率对比

Fig. 6 Comparison of recognition accuracy before and after adding anti-jitter mechanism

基于已知家电背景的负荷数据实验初步证明了结合Boruta-SHAP特征选择算法与v-NPSVM分类算法所构建的异常负荷辨识模型的有效性,下一步将结合实际未知家电背景的情况进行更深入的实验验证。

4.4 未知家电背景实验

在第1阶段的实验中,证明利用本文提出的Boruta-SHAP结合v-NPSVM算法模型可以有效进行识别针对

已知家电背景的数据集。但在实际应用中,每个家庭用户的家电背景往往是未知的,且不同用户的用电规律也不尽相同。故在第2阶段的实验中将针对未知家电背景的实测数据对算法进行验证。为进一步验证算法普适性,第2阶段的实验数据采用与第1阶段不同用户且含有电动车电池充电数据3户真实用户作为数据来源,总共有101个数据样本。为了验证v-NPSVM算法效果,与传统的支持向量机模型对比结果如图7所示。各个用户样本经过本文提出的算法判别后的充电事件识别正确率结果如图8所示。

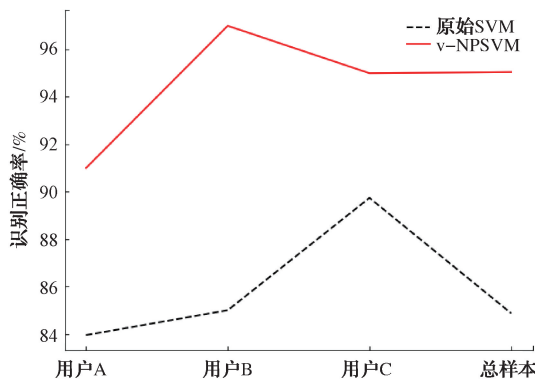


图7 原始支持向量机与v-NPSVM识别正确率对比
Fig. 7 Comparison of recognition accuracy between raw SVM and v-NPSVM

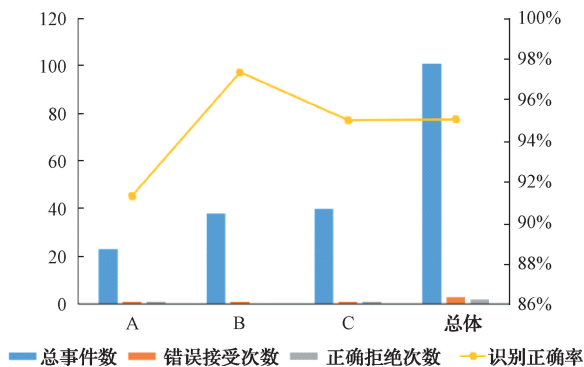


图8 针对未知家电背景数据的算法识别情况
Fig. 8 Algorithm recognition performance on known household appliance background

根据图7结果,v-NPSVM相较于传统支持向量机算法对于电动车电池充电负荷有着更好的辨识效果,可以得到的更高效算法模型。由图8结果可知,本文提出的算法模型针对未知家电背景以及用电规律的用户,整体的充电事件识别率达到了95.05%。

由于目前大部分台区电表采集频率甚至无法达到1/5 Hz,为进一步验证算法对于更低频数据的识别效果,将原始实验数据降频至1/15与1/30 Hz分别进行实验,实验结果如表2所示。

表2 各频率负荷数据识别正确率

Table 2 Recognition accuracy of various frequency

采样频率/Hz	load data			
	数据识别正确率/%			
用户 A	用户 B	用户 C	总样本	
1/5	91.3	97.36	95.00	95.05
1/15	86.96	94.74	92.5	92.08
1/30	82.61	92.11	92.5	90.01

通过表2的结果可以看出采样频率由1/5 Hz降低为1/15 Hz以及1/30 Hz后,算法整体的识别正确率略微下降。其中在1/15 Hz情况下总识别正确率为92.08%,1/30 Hz情况下总识别正确率为90.01%,故认为在最低为1/30 Hz的采样频率背景本文提出的算法可以较好地实现对家庭用户电动车入户充电事件的识别,本方法可以适用于大多数台区的场景,进一步证明了本方法的普适性。

5 结论

本文基于实际应用场景,提出了一种基于边缘计算的用户异常负荷识别方法。首先结合边缘计算技术与云计算技术建立了一个边缘计算平台,在边缘节点上完成对采集数据的预处理并上传云平台,由云平台利用采集数据完成对判别模型的训练,并将训练好的模型下发边缘节点,在边缘节点实现对异常负荷的识别并将结果发回云平台再进行进一步处理。对于异常负荷的具体识别算法,本文通过异常负荷中典型的电动车充电负荷进行验证。由于实测数据相比于实验室环境数据干扰更强且采集频率低,首先利用Boruta-SHAP算法对实测数据进行特征选择,筛选得到在基于秒级负荷数据情况下辨识能力更高的特征构建特征子集;接着基于v-NPSVM实现异常负荷的识别模型的构建;在经过v-NPSVM的初次判别后,加入防抖动机制对识别结果进行二次判别,从充电事件识别的角度提高了整个识别方法的正确率。在实验的过程中本文对训练集、测试集选择相同或不同的用户数据进行了验证,证明了本算法的普适性;针对智能电表采集的秒级数据进一步降频处理,在1/15和1/30 Hz数据集上对本文算法进行验证,实验结果证明,提出的识别方法在低频数据集中仍然有效。相较于传统的异常负荷识别方法,本文提出的方案为未来智能电表的异常负荷识别与异常事件检测提供思路,具有良好的应用前景。

参考文献

- [1] 唐斯斯,张延强,单志广,等.我国新型智慧城市发展现状、形势与政策建议[J].电子政务,2020(4):70-80.
TANG S S, ZHANG Y Q, SHAN ZH G, et al. The current situation, and policy recommendations for the development of new smart cities in China[J]. Elec-

- tronic Government, 2020(4): 70-80.
- [2] 丁宏军. 从消防角度看电动车的发展[J]. 建筑电气, 2019, 38(2): 3-7.
DING H J. Development of electric vehicles from the perspective of fire protection[J]. Building Electricity, 2019, 38(2): 3-7.
- [3] 郭广美. 火灾自动报警系统的巡检与维护[J]. 集成电路应用, 2023, 40(3): 120-121.
GUO G M. Analysis of patrol inspection and maintenance of automatic fire alarm system[J]. Applications of IC, 2023, 40(3): 120-121.
- [4] WU X, DUNNE R, ZHANG Q, et al. Edge computing-enabled smart firefighting: Opportunities and challenges[C]. 5th ACM/IEEE Workshop. ACM, 2017.
- [5] LI Y, GAO W. MUVR: Supporting multi-user mobile virtual reality with resource constrained edge cloud[C]. 2018 IEEE/ACM Symposium on Edge Computing (SEC), 2018: 1-16.
- [6] JIE C, LANYU X, ABDALLAH R, et al. An OS for internet of everything: Early experience from a smart home prototype[J]. ZTE Technology Journal, 2017, 15(4): 12-22.
- [7] GEIGER A, LENZ P, URTASUN R. Are we ready for autonomous driving? The KITTI vision benchmark suite[C]. IEEE Conference on Computer Vision & Pattern Recognition. IEEE, 2012.
- [8] HART G W. Nonintrusive appliance load monitoring[J]. Proceedings of the IEEE, 1992, 80(12): 1870-1891.
- [9] 陈军锋, 王雪, 张效天. 非侵入式负荷识别边缘计算颜色编码研究[J]. 仪器仪表学报, 2020, 41(9): 12-19.
CHEN J F, WANG X, ZHANG X T. Noninvasive load identification edge computing color coding research[J]. Chinese Journal of Scientific Instrument, 2020, 41(9): 12-19.
- [10] 方祖春, 汪繁荣. 基于非侵入式负荷分解的有色金属冶炼工序识别[J]. 国外电子测量技术, 2023, 42(1): 170-177.
FANG Z CH, WANG F R. Identification of nonferrous metal smelting process based on non-invasive load decomposition[J]. Foreign Electronic Measurement Technology, 2023, 42(1): 170-177.
- [11] 张文韬. 基于边缘计算的电动车入户充电检测方法研究[D]. 合肥: 安徽建筑大学, 2021.
ZHANG W T. Research on the detection method of electric vehicle in-home charging based on edge computing[D]. Hefei: Anhui Jianzhu University, 2021.
- [12] 栾文鹏, 马纯伟, 赵博超, 等. 非侵入式电动自行车充电负荷在线识别[J]. 电力系统及其自动化学报, 2022, 34(10): 1-7, 14.
LUAN W P, MA CH W, ZHAO B CH, et al. On-line identification of non-invasive electric bicycle charging load[J]. Proceedings of the CSU-EPSA, 2022, 34(10): 1-7, 14.
- [13] 施雨松, 徐青山, 郑建. 基于特征选择与增量学习的非侵入式电动自行车充电辨识方法[J]. 电力系统自动化, 2021, 45(7): 87-94.
SHI Y S, XU Q SH, ZHENG J. A non-invasive electric bicycle charging identification method based on feature selection and incremental learning[J]. Automation of Electric Power Systems, 2021, 45(7): 87-94.
- [14] 杨东升, 孔亮, 胡博, 等. 基于多特征序列融合的负荷辨识方法[J]. 电力系统自动化, 2017, 41(22): 66-73.
YANG D SH, KONG L, HU B, et al. Load identification method based on multi feature sequence fusion[J]. Automation of Electric Power Systems, 2017, 41(22): 66-73.
- [15] 王守相, 郭陆阳, 陈海文, 等. 基于特征融合与深度学习的非侵入式负荷辨识算法[J]. 电力系统自动化, 2020, 44(9): 103-110.
WANG SH X, GUO L Y, CHEN H W, et al. Non-intrusive load identification algorithm based on feature fusion and deep learning[J]. Automation of Electric Power Systems, 2020, 44(9): 103-110.
- [16] 周晨轶, 刘松, 钟潇, 等. 基于差分进化算法的居民用电负荷分解方法[J]. 南方电网技术, 2016, 10(6): 62-69.
ZHOU CH Y, LIU S, ZHONG X, et al. Differential evolution algorithm based residential load decomposition[J]. Southern Power System Technology, 2016, 10(6): 62-69.
- [17] KURSA M B, RUDNICKI W R. Feature selection with boruta package[J]. Journal of Statistical Software, 2010, 36(11): 1-13.
- [18] TIAN Y, ZHANG Q, LIU D. ν -Nonparallel support vector machine for pattern classification[J]. Neural Computing & Applications, 2014, 25(5): 1007-1020.
- [19] SHAO Y H, CHEN W J, DENG N Y. Nonparallel hyperplane support vector machine for binary classification problems[J]. Information Sciences, 2014, 263: 22-35.
- [20] 吕志宁, 赵少东, 饶竹一, 等. 非侵入负荷辨识的谐波特征量提取改进方法研究[J]. 电子测量技术, 2019, 42(7): 29-34.
LYU ZH N, ZHAO SH D, RAO ZH Y, et al. Improved method research on extracting load harmonic

- feature for non-intrusive load monitoring[J]. *Electronic Measurement Technolog*, 2019, 42(7): 29-34.
- [21] KURSA M B. Feature selection with the Boruta algorithm[Z]. *R-Bloggers*, 2017.
- [22] KURSA M B, JANKOWSKI A, RUDNICKI W R. Boruta-A system for feature selection[J]. *Fundamenta Informaticae*, 2010, 101(4): 271-285.
- [23] CHEN Z, QI Z, WANG B, et al. Learning with label proportions based on nonparallel support vector machines[J]. *Knowledge-Based Systems*, 2017, DOI: 10.1016/j.knsys.2016.12.007.
- [24] ZHU G Y, HUANG D, ZHANG P. Linear programming v-Nonparallel support vector machine[C]. 2014 International Conference on Identification, Information and Knowledge in the Internet of Things, 2014.
- [25] 应鸿, 姜黎莉, 李鑫, 等. 基于 v-NPSVM 的暂态稳定评估方法研究[J]. *东北电力大学学报*, 2018, 38(5): 31-40.
- YING H, JIANG L L, LI X, et al. Research on transient stability assessment method based on v-NPSVM[J]. *Journal of Northeast Electric Power University*, 2018,

38(5): 31-40.

作者简介

周玉, 硕士, 高级工程师, 主要研究方向为电能计量、电网数据挖掘等。

E-mail: ZHOUYU1561@163.com

张震, 硕士, 工程师, 主要研究方向为电能计量、数据挖掘。

E-mail: zhenzhang0111@163.com

马云龙, 硕士研究生, 高级工程师, 主要研究方向为电力系统及其自动化等。

E-mail: myl1232024@163.com

李悦, 硕士研究生, 高级工程师, 主要研究方向为研究电能计量等。

E-mail: lygnr12@aliyun.com

高凡, 硕士研究生, 工程师, 主要研究方向为电能计量等。

E-mail: 84990062113@qq.com

韦喆(通信作者), 硕士研究生, 主要研究方向为电力信号处理、数据挖掘等。

E-mail: 211307020011@hhu.edu.com