

基于VMD-LSTM的非侵入式负荷识别方法

王毅¹, 易欢¹, 李松浓², 冯凌³, 刘期烈¹, 宋如楠⁴

(1.重庆邮电大学通信与信息工程学院, 重庆400065; 2.国网重庆市电力公司电力科学研究院, 重庆400014;
3.国网重庆市电力公司营销服务中心, 重庆400014; 4.中国电力科学研究院, 北京100192)

摘要: 非侵入式负荷识别(Non-Intrusive Load Monitoring, NILM)技术仅基于家庭电源总入口处的电流、电压信息, 获得室内电器设备的电气信息。提高负荷识别的精度, 对于优化能源结构、提高电能利用效率、降低能耗、节约资源具有重要意义。首先应用变分模态分解(Variational Mode Decomposition, VMD)对归一化的电流信号分解为K个IMF分量, 再估计各个分量与归一化电流信号的相关系数, 挑选相关系数最大的两个分量作为负荷特征, 输入训练好的LSTM神经网络进行识别。算例测试结果表明, 该方法在公开数据集PLAID上的识别率高达99%, 在实验室采集的数据集上的识别率为96.6%, 证实了所提出方法对提升负荷识别精度有显著效果。

关键词: 变分模态分解; 智能电网; LSTM; 相关系数

中图分类号: TM721

文献标志码: A

DOI: 10.16157/j.issn.0258-7998.223024

中文引用格式: 王毅, 易欢, 李松浓, 等. 基于VMD-LSTM的非侵入式负荷识别方法[J]. 电子技术应用, 2023, 49(2): 127-132.

英文引用格式: Wang Yi, Yi Huan, Li Songnong, et al. Non-intrusive load identification method based on VMD-LSTM[J]. Application of Electronic Technique, 2023, 49(2): 127-132.

Non-intrusive load identification method based on VMD-LSTM

Wang Yi¹, Yi Huan¹, Li Songnong², Feng Ling³, Liu Qilie¹, Song Runan⁴

(1.Communication and Information Engineering College, Chongqing University of Posts and Telecommunications, Chongqing 400067, China; 2.Chongqing Electric Power Research Institute, Chongqing 400014, China;
3.Postdoctoral Workstation of the Chongqing Electric Power Corporation, Chongqing 400014, China;
4.China Electric Power Research Institute, Beijing100192, China)

Abstract: Non-intrusive load monitoring (NILM) technology is only based on the current and voltage information of the main entrance of home power supply to obtain the electrical information of indoor electrical equipment. Improving the accuracy of load identification is of great significance to optimize the energy structure, improve the efficiency of power utilization and reduce energy consumption. Firstly, the normalized current signal is decomposed by using variational mode decomposition (VMD), and then the correlation coefficients between each component and the original current signal are calculated. The two components with the largest correlation coefficients are selected as the load characteristics and input into the trained LSTM neural network for identification. The test results of an example show that the recognition rate of this method is up to 99% on public data set PLAID and 96.6% on laboratory data set, which proves the effectiveness of this method.

Key words: variational mode decomposition; smart grid; LSTM; correlation coefficient

0 引言

随着社会的发展, 电力成为社会的主要能源。电网是电力运输、分配和使用的载体。保持智能电网的稳定运行是电力系统规划和管理的根本目标^[1]。负荷监测可以帮助电力公司获得用户的详细用电信息, 分析用户用电信息可以为电力系统的规划和智能调度提供指导意见^[2]。对电力用户来说, 可以通过负荷监测结果分析自

己的用电行为, 制定合理的用电策略, 降低用电成本, 节约能源资源。侵入式负荷监测(Intrusive Load Monitoring, ILM)和非侵入式负荷监测(Non-Intrusive Load Monitoring, NILM)是电力监控的两种手段。ILM系统需在每个家用电器的前端安装测量传感器, 用以实时的记录设备的用电信息, 其成本与电器的数量成线性关系; NILM由美国麻省理工学院的Hart^[3]教授于20世纪

80年代提出,仅通过家庭入口处的电流电压信息,采用算法得到各用电器的电气信息。与ILM系统相比,NILM系统有安装方便、成本低、保护隐私安全等优点。非侵入式负荷识别主要有两种实现方法,即事件法^[4]和分解法^[5,6]。事件法检测电器设备的启动/关闭事件,以事件的瞬态变化为特征判断电器的类型,从而推断电器的实时工作状态,实现电能的分解。分解法是直接从多负载叠加的电气特性分解为每个电器特性最可能的组合。但随着电器设备数量的增多,分解法的复杂度大大提高,而事件法则没有上述缺点。事件法的关键在于对电器产生的负荷投切事件进行准确分类。

文献[7]采用孪生神经网络结合空间凸包重叠率的相似性计算方法,在保证已知负荷的识别精度的基础上,引入迁移学习实现了未知负荷的识别。文献[8]采用电压和电流的总体变化作为负载特征,根据循环中电压电流变化的差异提取V-I轨迹的特征,以带有附加注意模块的卷积神经网络进行负载识别,但特征提取步骤较繁琐且V-I轨迹的训练占用计算资源大。文献[9]采用有功功率和无功功率作为第一层中识别负载的特征,以电流的三次谐波和五次谐波作为第二层中识别负载的特征,通过KNN进行负荷的识别。文献[10]采用局部均值平均法(LMD)结合KNN的方法,通过LMD将有功功率进行分解,将分解得到的分量作为设备的唯一负载指纹,有效增加了相似负荷的识别率,但是对KNN的K值以及LMD的分解维数都需要根据经验得到,存在不确定性。文献[11]采用随机森林对负荷特征进行优选,再利用经过遗传算法优化的极限学习机进行负荷分类。文献[12]先采用有功功率和无功功率作为负荷特征,采用k-means算法进行聚类,针对一阶段的识别盲区,构建卷积神经网络,以V-I轨迹作为负荷特征进行二次识别,但模型训练时间长。文献[13]在电压满足一定条件的情况下采集负荷稳态波形作为负荷特征,利用动态时间弯曲(DTW)算法计算稳态波形与模板库的距离来识别负荷,但是在测量稳态波形时对电压有严格要求且对小电流设备的工作状态容易误判。

针对以上方法存在的缺陷,本文采用VMD对归一化的单周期稳态电流信号进行分解,求分解后分量与归一化信号的相关系数,选相关系数最大的两个分量作为电器的负荷特征,输入训练好的LSTM神经网络进行识别。该方法不仅提高了相似性负荷的识别率,且模型训练时间短,花费计算资源较少。通过PLAID数据集和实验室采集数据进行仿真实验,证明了本文方法的有效性。

1 特征构建

1.1 VMD算法原理

变分模态分解(Variational Mode Decomposition,

VMD)是Dragomiretskiy K^[14]等人于2014年提出的一种新的非线性、非平稳信号的自适应分解计算方法。该方法认为各个IMF分量都是集中在中心频率附近的窄带信号。根据IMF分量的窄带条件建立约束问题来估计IMF分量的中心频率和重构IMF分量。

电流的原始信号为 $i(t)$, $i_k(t)$ 为经VMD分解的K个离散模态分量, $k=1,2,\dots,K$ 。

算法分解步骤如下:

(1)应用Hilbert变换获取每个模态分量 $i_k(t)$ 的单边谱,如式(1)所示:

$$S_k = \left(\delta(t) + \frac{j}{\pi t} \right) * i_k(t) \quad (1)$$

式中: $\delta(t)$ 为狄拉克函数。

(2)将每个模态分量 $i_k(t)$ 频谱搬移到相应基频带,如式(2)所示:

$$S_{ik} = \left[\left(\delta(t) + \frac{j}{\pi t} \right) * i_k(t) \right] e^{-j\omega_k t} \quad (2)$$

式中: ω_k 为 $i_k(t)$ 的中心频率。

(3)通过对各模态分量 $i_k(t)$ 解调信号的高斯平滑方式估计各模态分量的带宽,构造式(3)所示的约束变分模型:

$$\begin{cases} \min_{\{i_k\}, \{\omega_k\}} \left\{ \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * i_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \\ \text{s.t. } \sum_k i_k(t) = x(t) \end{cases} \quad (3)$$

式中: ∂_t 为对 t 求偏导。引入拉格朗日乘子 λ 和二次惩罚因子 α ,通过增广拉格朗日函数将上述等式约束优化问题等效为一个无约束优化问题,如式(4)所示:

$$\begin{aligned} L(\{I_k\}, \{\omega_k\}, \lambda) = & \\ & \alpha \sum_k \left\| \left[\left(\delta(t) + \frac{j}{\pi t} \right) * i_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \\ & \left\| x(t) - \sum_k i_k(t) \right\|_2^2 + \left\langle \lambda(t), x(t) - \sum_k i_k(t) \right\rangle \end{aligned} \quad (4)$$

采用交替方向乘子法ADMM和Parseval定理交替迭代更新 i_k^{n+1} 、 ω_k^{n+1} 、 λ^{n+1} ,直至满足迭代终止条件:

$$\sum_k \left(\frac{\|i_k^{n+1} - i_k^n\|_2^2}{\|i_k^n\|_2^2} \right) < \varepsilon \quad (5)$$

式中: ε 为求解精度。

求解过程中单个变量的更新表达式如式(6)、式(7)、式(8)所示:

$$\hat{i}_k^{n+1}(\omega) = \frac{\hat{x}(\omega) - \sum_{i=1}^{k-1} \hat{u}_i^{n+1}(\omega) - \sum_{i=k+1}^K \hat{u}_i^n(\omega) + \frac{\hat{\lambda}^n(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (6)$$

$$\hat{\omega}_k^{n+1} = \frac{\int_0^\infty \omega |\hat{i}_k^{n+1}(\omega)|^2 d\omega}{\int_0^\infty |\hat{i}_k^{n+1}(\omega)|^2 d\omega} \quad (7)$$

$$\hat{\lambda}^{n+1}(\omega) = \hat{\lambda}^n(\omega) + \gamma \left(\hat{x}(\omega) - \sum_{k=1}^K \hat{i}_k^{n+1}(\omega) \right) \quad (8)$$

式中： γ 为噪声容忍度。

1.2 基于VMD的特征构建

非侵入式负荷监测系统中,数据质量是影响识别精度的重要因素。且不同的采样频率、不同的采样设备得到的数据会有一些的不同。为减小不同采集设备采集数据的差异,本文对电流进行归一化处理,将电流归一化到(-1,1)范围。归一化按式(9)进行处理:

$$i_{nor} = \frac{i(t) - i_{min}}{i_{max} - i_{min}} \quad (9)$$

式中: i_{nor} 代表归一化电流数据, i_{max} 为单周期内电流的最大值, i_{min} 为单周期内电流的最小值。

笔记本稳态电流经VMD分解为5个IMF分量的波形如图1所示。

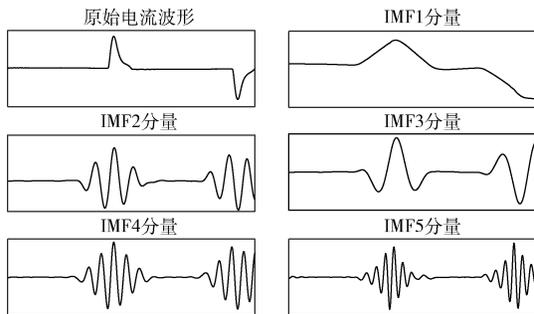


图1 笔记本原始电流及分量波形

计算各IMF分量与归一化后电流信号的相关系数,将相关系数最大的两个IMF分量合并为一维向量作为该负荷的负载特征。

笔记本的负荷特征曲线如图2所示。横轴为采样点的个数,单周期的采样点为500,分解后的每个分量的采样点也为500,故合并后的特征的采样点为1000。

2 LSTM网络模型及识别流程

2.1 LSTM网络模型

在循环神经网络(RNN)的基础上引入了遗忘门、输入门和输出门控制每个细胞单元的状态得到长短期记忆神经网络(LSTM)^[15],它解决了RNN梯度消失和梯度爆炸等问题。LSTM的模型内部结构如图3所示。

f_t 为遗忘门、 W_f 为遗忘门的权重矩阵; i_t 为输入门, W_i 输入门的权重矩阵; o_t 为输出门, W_o 为输出门的权重矩阵。各计算公式如式(10)所示:

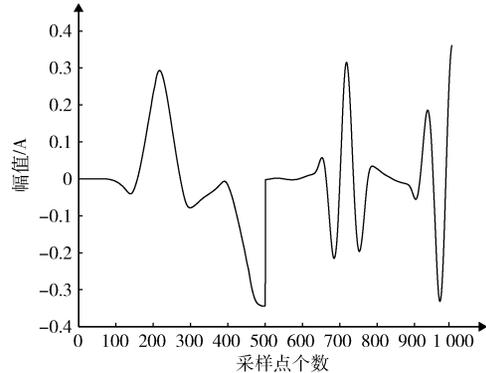


图2 笔记本负荷特征波形

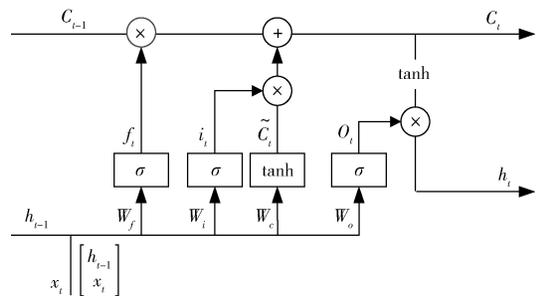


图3 LSTM内部结构图

$$\begin{cases} X = [h_{t-1} \ x_t]^T \\ f_t = \sigma(W_f X + b_f) \\ o_t = \sigma(W_o X + b_o) \\ C_t = f_t C_{t-1} + i_t \tanh(W_c X + b_c) \\ h_t = o_t \tanh(C_t) \end{cases} \quad (10)$$

2.2 识别流程

负荷识别流程如图4所示,首先经过稳态数据的采集得到设备的稳态电流,将稳态周期电流经VMD分解,得到各分量波形;将与归一化后电流信号相关系数最大的两个分量拼接为一维负荷特征,输入训练好的LSTM网络进行负荷识别。

3 算例测试及分析

本文采用基于Python 3.6平台TensorFlow 2.0的深度神经网络。硬件平台为Intel(R) Core(TM) i5-6500 CPU 3.2 GHz、8 GB RAM。

3.1 评价指标

本文采用混淆矩阵全面地评价分类结果。评价指标 P_{re} 代表当前样本的准确率, R_{re} 代表召回率, F_1 代表准确率和召回率的平均评估指标^[16]。计算公式如式(11)、式(12)、式(13)所示:

$$P_{re} = \frac{TP}{TP + FP} \quad (11)$$

$$R_{re} = \frac{TP}{TP + FN} \quad (12)$$

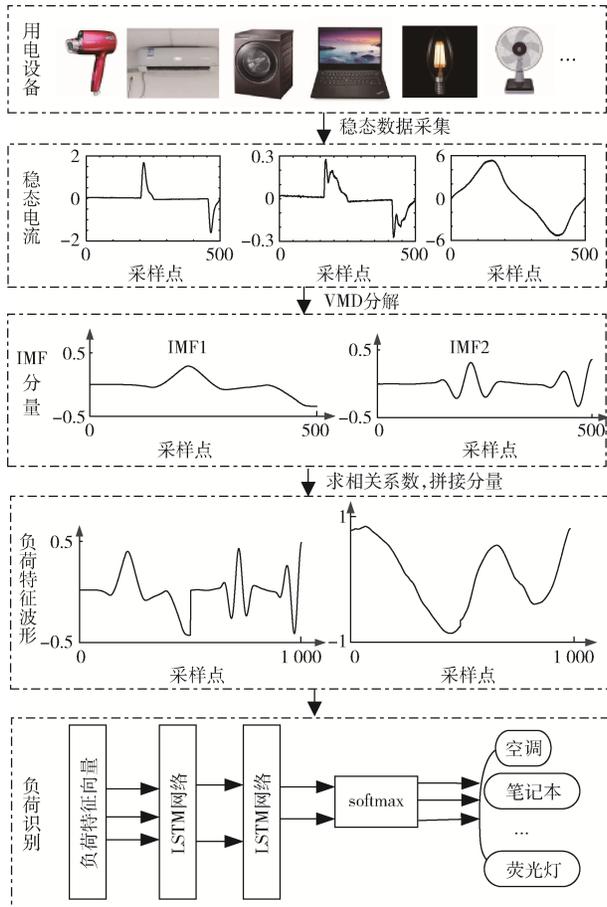


图4 负荷识别流程

$$F_1 = \frac{2P_{re}R_{re}}{P_{re} + R_{re}} \quad (13)$$

其中TP表示真实和预测都为正类的数量;TN表示实际和预测都是负类的数量;FP表示实际为负类,但预测为正类的数量;FN表示实际为正类,但被预测为负类的数量。

3.2 PLAID数据集算例分析

PLAID数据集,采样频率为30 kHz,该数据集记录了美国宾夕法尼亚州55个家庭用户的用电数据,包括11种不同的电器1793组电压、电流数据^[17]。提取各个电器的180个稳态周期的电流数据,经过VMD分解后选择与归一化信号相关系数最大的两个分量作为负荷特征,构建成1×1000的一维负荷特征。文中训练数据集与测试数据集的比例为7:3,总数分别为1386和594。实验仿真结果绘制的混淆矩阵如图5所示。

混淆矩阵中,纵轴表示用电设备的实际类别,横轴表示预测类别,矩阵中斜对角线上的数字表示正确识别的数量,其他位置的数字表示未被正确识别的数量。百分数表示当前类别数量占测试集总样本的比例,最右侧的百分数表示准确率,最下侧的百分比表示召回率。从中可以看到,各个电器的识别率都在96%以上,整体识

| 实际值 | 空调 | 节能灯 | 风扇 | 冰箱 | 吹风机 | 烘干机 | 白炽灯 | 笔记本 | 微波率 | 吸尘器 | 洗衣机 | 准确率 |
|-----|--------------|--------------|--------------|--------------|---------------|--------------|--------------|---------------|--------------|---------------|---------------|---------------|
| 空调 | 58 9.8% | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 100% 0.0% |
| 节能灯 | 0 0.0% | 50 8.4% | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 100% 0.0% |
| 风扇 | 0 0.0% | 0 0.0% | 48 8.1% | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 100% 0.0% |
| 冰箱 | 0 0.0% | 0 0.0% | 0 0.0% | 54 9.1% | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 100% 0.0% |
| 吹风机 | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 62 10.4% | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 100% 0.0% |
| 烘干机 | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 59 9.9% | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 1 0.2% | 98.3% 1.7% |
| 白炽灯 | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 2 0.3% | 43 7.2% | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 95.6% 4.4% |
| 笔记本 | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 46 7.7% | 0 0.0% | 0 0.0% | 0 0.0% | 100% 0.0% |
| 微波率 | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 52 8.8% | 0 0.0% | 1 0.2% | 98.1% 1.9% |
| 吸尘器 | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 62 10.4% | 0 0.0% | 100% 0.0% |
| 洗衣机 | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 1 0.2% | 0 0.0% | 0 0.0% | 0 0.0% | 1 0.2% | 54 9.1% | 96.4% 3.6% |
| 召回率 | 100% 0.0% | 100% 0.0% | 100% 0.0% | 100% 0.0% | 95.2% 4.8% | 100% 0.0% | 100% 0.0% | 98.1% 1.9% | 100% 0.0% | 96.4% 3.6% | 99.0% 1.0% | |

图5 PLAID数据集LSTM识别结果绘制的混淆矩阵

别率达到了99%,说明本文方法有效。

3.3 与其他算法的对比

为了进一步说明本文方法的有效性,与其他负荷识别算法进行对比,表1列出了各个算法的设备识别率,实验均在PLAID数据集上进行。各算法的准确率如表1所示。

表1 与其他识别算法的识别率对比

| 用电器 | 识别率 | | | | |
|-----|--------|--------|--------|--------|------|
| | 文献[18] | 文献[19] | 文献[20] | 文献[21] | 本文方法 |
| 空调 | 0.31 | 0.74 | 0.73 | 0.75 | 1.00 |
| 节能灯 | 0.93 | 0.98 | 1.00 | 1.00 | 1.00 |
| 风扇 | 0.53 | 0.93 | 0.74 | 0.75 | 1.00 |
| 冰箱 | 0.36 | 0.57 | 0.73 | 0.70 | 1.00 |
| 吹风机 | 0.87 | 1.00 | 1.00 | 1.00 | 1.00 |
| 加热器 | 0 | 0.55 | 0.90 | 0.95 | 0.98 |
| 白炽灯 | 0.90 | 0.99 | 1.00 | 1.00 | 0.96 |
| 笔记本 | 0.98 | 0.90 | 0.56 | 1.00 | 1.00 |
| 微波率 | 0.93 | 1.00 | 1.00 | 1.00 | 0.98 |
| 吸尘器 | 0.81 | 0.86 | 0.95 | 1.00 | 1.00 |
| 洗衣机 | 0.57 | 0.56 | 0.81 | 0.85 | 0.96 |
| 平均 | 0.77 | 0.85 | 0.88 | 0.91 | 0.99 |

其中文献[18]提取V-I轨迹图像的轮廓特征,利用这些特征计算椭圆傅里叶描述符作为负荷特征,利用多层感知机进行分类。文献[19]采用自动选择设备特征的递归特征消除算法,以随机森林作为分类算法。文献[20]采用稳态、暂态相结合的负荷特征,利用基于PCA的辨识分类算法进行分类。文献[21]使用V-I轨迹图像结合功率作为负荷特征,以BP神经网络进行分类。由表1可知,相比于参考文献中的方法,本文方法采用VMD分解

单周期稳态电流,计算分量与归一化电流信号的相关系数,挑选相关系数最大的两个分量作为负荷特征,增加了算法的辨识能力。

3.4 实验室自采数据集实验仿真及分析

实验室采集数据采用1 000:1的电流互感器,Pico-Scope 5000 series进行数据采集。用电设备信息如表2所示。

表2 实验室所用设备信息

| 设备名称 | 额定功率/W |
|------|--------|
| 白炽灯 | 200 |
| 吹风机 | 1 200 |
| 热水壶 | 2 000 |
| 烘干机 | 2 000 |
| 电烙铁 | 40 |
| 笔记本 | / |

实验室自采数据集采样频率为5 kHz,包括6种电器共1 080个电流周期数据。经VMD分解后选用与归一化电流信号相关系数最大的两个分量拼接为1×200的一维向量作为负荷特征。与PLAID数据集一样,训练集与测试集的比例为7:3,训练集和测试集的样本总数分别为756、324。经训练后的LSTM模型分类效果如图6混淆矩阵所示。

| | | | | | | | | |
|-----|-----|---------------|--------------|--------------|---------------|---------------|---------------|----------------|
| 实际值 | 白炽灯 | 43 13.3% | 0 0.0% | 0 0.0% | 0 0.0% | 2 0.6% | 0 0.0% | 95.6% 4.4% |
| | 笔记本 | 0 0.0% | 57 17.6% | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 100% 0.0% |
| | 吹风机 | 0 0.0% | 0 0.0% | 57 17.6% | 0 0.0% | 0 0.0% | 0 0.0% | 100% 0.0% |
| | 电烙铁 | 1 0.3% | 0 0.0% | 0 0.0% | 45 13.9% | 0 0.0% | 5 1.5% | 88.2% 11.8% |
| | 烘干机 | 0 0.0% | 0 0.0% | 0 0.0% | 0 0.0% | 57 17.6% | 0 0.0% | 100% 0.0% |
| | 热水壶 | 0 0.0% | 0 0.0% | 0 0.0% | 3 0.9% | 0 0.0% | 54 16.7% | 94.7% 5.3% |
| | | 97.7% 2.3% | 100% 0.0% | 100% 0.0% | 93.8% 6.3% | 96.6% 3.4% | 91.5% 8.5% | 96.6% 3.4% |
| | | 白炽灯 | 笔记本 | 吹风机 | 电烙铁 | 烘干机 | 热水壶 | |
| | | 预测值 | | | | | | |

图6 实验室采集数据集LSTM识别结果绘制的混淆矩阵

3.5 数据集结果差异分析

整体来看,该方法在PLAID数据集上的识别率高于实验室采集数据的识别率,分析主要的原因在于PLAID数据集相似性负荷较少,而实验室采集的数据相似性负荷较多。另外一方面是采样频率的不同,PLAID的采样频率为30 kHz,而实验室采集的数据是5 kHz,采样频率

越高,则采集得到的数据含有的负荷信息就会更多,经VMD分解后会有更多的特征信息。

4 结论

针对相似性负荷识别率较低的问题,本文提出一种VMD结合LSTM的负荷识别方法。先将归一化的单周期稳态电流用VMD进行分解,再计算各分量与归一化电流信号的相关系数,将与归一化信号相关系数最大的两个分量作为负荷特征,采用LSTM神经网络进行识别。在公开数据集PLAID上进行仿真验证,仿真结果的识别率为99%,表明本文方法的有效性。与其他负荷识别算法对比,本文所提方法可以得到更多的负荷特征信息,可以有效地提高识别率。最后在实验室采集的数据集上进行了仿真验证,96.6%的识别率充分说明本文所提方法拥有良好的鲁棒性。

参考文献

- [1] LI Y, YANG Y, SIMA K, et al. Non-intrusive load monitoring based on harmonic characteristics[J]. Procedia Computer Science, 2021, 183: 776-782.
- [2] 崔高辰. 基于深度学习的目标电器电量估计[D]. 天津: 天津大学, 2018.
- [3] HART G W. Nonintrusive appliance load monitoring[J]. Proceedings of the IEEE, 1992, 80(12): 1870-1891.
- [4] LIN Y H, TSAI M S. Applications of hierarchical support vector machines for identifying load operation in nonintrusive load monitoring systems[C]//2011 9th World Congress on Intelligent Control and Automation. IEEE, 2011: 688-693.
- [5] 孙毅, 崔灿, 陆俊, 等. 基于遗传优化的非侵入式家居负荷分解方法[J]. 电网技术, 2016, 40(12): 3912-3917.
- [6] 于超, 覃智君, 阳育德. 基于启停状态识别改进因子隐马尔可夫模型的非侵入式负荷分解[J]. 电网技术, 2021, 45(11): 4540-4550.
- [7] YIN B, ZHAO L, HUANG X, et al. Research on non-intrusive unknown load identification technology based on deep learning[J]. International Journal of Electrical Power & Energy Systems, 2021, 131: 107016.
- [8] SHI Z, YIN B. An improved non-intrusive load identification method for VI trajectory based on amplitude to pixel value [C]//2021 IEEE 5th Information Technology, Networking, Electronic and Automation Control Conference (ITNEC). IEEE, 2021, 5: 1510-1516.
- [9] TAO P, LIU X A, ZHANG Y, et al. Multi-level non-intrusive load identification based on k-NN[C]//2019 IEEE 3rd Conference on Energy Internet and Energy System Integration (EI2). IEEE, 2019: 1905-1910.
- [10] Pengfei Y, Xianbo S, Li Z, et al. Non-intrusive load monitoring method based on LMD and KNN algo-

- rithm[C] //2021 IEEE International Conference on Electrical Engineering and Mechatronics Technology (ICEEMT). IEEE, 2021: 692-698.
- [11] 安琪,王占彬,安国庆,等.基于随机森林-遗传算法-极限学习机的非侵入式负荷识别方法[J].科学技术与工程,2022,22(5):1929-1935.
- [12] 汪颖,杨维,肖先勇,等.基于U-I轨迹曲线精细化识别的非侵入式居民负荷监测方法[J].电网技术,2021,45(10):4104-4113.
- [13] 祁兵,董超,武昕,等.基于DTW算法与稳态电流波形的非侵入式负荷辨识方法[J].电力系统自动化,2018,42(3):70-76.
- [14] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2013, 62(3): 531-544.
- [15] GRAVES A. Long short-term memory[J]. Supervised Sequence Labelling with Recurrent Neural Networks, 2012: 37-45.
- [16] 解洋,梅飞,郑建勇,等.基于V-I轨迹颜色编码的非侵入式负荷识别方法[J].电力系统自动化,2022,46(4):93-102.
- [17] 武昕,焦点,高宇辰.基于非侵入式用电数据分解的自适应特征库构建与负荷辨识[J].电力系统自动化,2020,44(4):101-109.
- [18] DE BAETS L, DEVELDER C, DHAENE T, et al. Automated classification of appliances using elliptical Fourier descriptors[C]//2017 IEEE International Conference on Smart Grid Communications (SmartGridComm). IEEE, 2017: 153-158.
- [19] SADEGHIANPOURHAMAMI N, RUYSSINCK J, DESCHRIJVER D, et al. Comprehensive feature selection for appliance classification in NILM[J]. Energy and Buildings, 2017, 151: 98-106.
- [20] ALCALÁ J, UREÑA J, HERNÁNDEZ Á, et al. Event-based energy disaggregation algorithm for activity monitoring from a single-point sensor[J]. IEEE Transactions on Instrumentation and Measurement, 2017, 66(10): 2615-2626.
- [21] 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.

(收稿日期:2022-05-25)

作者简介:

王毅(1981-),男,博士后,副教授,主要研究方向:智能电网、电力物联网。

易欢(1996-),通信作者,男,硕士研究生,主要研究方向:负荷识别, E-mail: 1343498564@qq.com。



扫码下载电子文档

版权声明

经作者授权，本论文版权和信息网络传播权归属于《电子技术应用》杂志，凡未经本刊书面同意任何机构、组织和个人不得擅自复印、汇编、翻译和进行信息网络传播。未经本刊书面同意，禁止一切互联网论文资源平台非法上传、收录本论文。

截至目前，本论文已经授权被中国期刊全文数据库（CNKI）、万方数据知识服务平台、中文科技期刊数据库（维普网）、DOAJ、美国《乌利希期刊指南》、JST日本科技技术振兴机构数据库等数据库全文收录。

对于违反上述禁止行为并违法使用本论文的机构、组织和个人，本刊将采取一切必要法律行动来维护正当权益。

特此声明！

《电子技术应用》编辑部

中国电子信息产业集团有限公司第六研究所