

基于VMD-CNN的非侵入式负荷监测方法研究

刘仲民,赵丹阳

(兰州理工大学 电气工程与信息工程学院,甘肃 兰州 730050)

摘要:非侵入式负荷监测通过在总电力接口处安装智能电表,实时采集和分析用户用电信息,从而监测各个用电设备的工作状态。针对电力系统中家庭用户负荷变化呈现的不同特性,提出一种基于VMD-CNN的非侵入式负荷监测方法。首先对采集到的负荷信号进行预处理,用变分模态分解方法将原始负荷功率信号分解成不同频率的有限带宽子序列,然后用Hilbert算法提取低频信号特征并将其输入到卷积神经网络中,再通过网络的自动学习能力学习各模态分量的不同特征,最后用全连接网络对用电设备进行分类,得到各个设备的用电情况。为了验证该方法,采用UK-DALE数据集进行实验验证,并与不同的分类算法进行对比。实验结果证明该方法适用于负荷监测且负荷监测精度达到了0.98。

关键词:非侵入式负荷监测;电力系统;VMD算法;卷积神经网络

中图分类号:TM73 **文献标识码:**A **DOI:**10.19457/j.1001-2095.dqcd24050

Research on Non-invasive Load Monitoring Method Based on VMD-CNN

LIU Zhongmin, ZHAO Danyang

(School of Electrical Engineering and Information Engineering, Lanzhou University of Technology,
Lanzhou 730050, Gansu, China)

Abstract: Non-invasive load monitoring monitors the working status of each electric equipment by installing an intelligent meter at the main power interface, aiming to collect and analyze users' power consumption information in real time. According to different characteristics of household user load change in power system, a non-invasive load monitoring method based on VMD-CNN was proposed. Firstly, the collected load signal was preprocessed, and the original load power signal was decomposed into finite bandwidth subsequences with different frequencies by variational modal decomposition method. Secondly, the low-frequency signal features were extracted by Hilbert algorithm and input into convolutional neural network, after which different features of each modal component were learned through the automatic learning ability of the network. Finally, the full connection network was used to classify the electrical equipment, and the power consumption of each equipment was obtained. In order to verify this method, the UK-DALE data set was used for experimental verification, and to compared with different classification algorithms. The experimental results proved that the method is suitable for load monitoring, and the load monitoring accuracy reaches 0.98.

Key words: non-invasive load monitoring (NILM); power system; variational model decomposition (VMD) algorithm; convolutional neural network (CNN)

非侵入式负荷监测(non-invasive load monitoring, NILM)系统通过在家庭总电力接口处安装智能电表以获取每个电器设备的功耗情况^[1],和传统的NILM方法相比,具有安装维护简单、便于数据采集和分析的优点。利用NILM得到的用电信息具有很大的实用价值^[1]。对于电网公司而

言,NILM能够帮助电网公司加强负荷侧管理,为电价调度服务提供数据支撑^[2];对于电力用户而言,NILM允许用户使用便携式设备实时观测用电量数据,在监控家庭能源使用情况的同时帮助用户估算电费,对家庭节能计划具有重要意义^[3]。

NILM在特征提取上分为依赖事件检测^[4-5]和

基金项目:国网甘肃省电力公司电力科学研究院科技项目(52273118000Y)

作者简介:刘仲民(1978—),男,博士,副教授,Email:liuzhmx@163.com

通讯作者:赵丹阳(1994—),女,硕士,Email:1490351050@qq.com

不依赖事件检测^[6];在采样频率上分为低频采样和低频采样。其中,依赖事件检测的方法有较好的运算效率,但数据在事件检测过程中易受噪声污染,监测效果并不理想。不依赖事件检测的方法包括各类深度学习算法,近年来应用广泛。文献[7]将电器分为状态复杂和简单两类,采用树结构 Parzen 估计算法选择网络的超参数以提高负荷训练精度。文献[8]提出一种基于多序列到点与时间标记编码的 NILM 模型,该方法对大功率设备具有较好的负荷监测效果,但对小功率设备监测效果并不理想。文献[9]通过局部平均算法对混合信号进行负荷分离,建立卷积神经网络(convolutional neural networks, CNN)模型进行负荷辨识,该方法能从混合信号中辨识出各个运行设备的电流信号,但不能有效判别具有相似波形的负荷。此外,一些学者通过高频采样来提取高频电流谐波^[10]、电压-电流($V-I$)轨迹特征^[11]和电器打开时的瞬态波形^[12]进行负荷监测。文献[13]将 $V-I$ 轨迹图像特征与功率数值特征进行融合,结合深度学习实现 NILM,虽然该方法运算速度较快,但监测准确率不高。文献[14]将变分模态分解(variational model decomposition, VMD)和随机森林结合进行负荷监测,取得了不错的效果。VMD 相较于经验模态来说,能克服模态分量混叠的问题,表现出较强的抗噪能力和稳定性,可以

很好地反映信号特征,而随机森林中决策树个数增多会使得训练空间和时间增大。目前,在 NILM 领域应用较多的为低频数据,而低频采样信号通常存在分辨率低、负荷特征容易混叠的现象^[15]。

综上所述,针对低频采样信号分辨率低、大功率设备和小功率设备难以同时获得较好的监测准确度的缺点,本文利用 VMD 的信号特征表征能力和抗噪性能对负荷功率信号进行预处理,联合 CNN 的高分辨率特性及自动学习能力进行负荷监测。

1 负荷监测模型结构

整体负荷主要包括负荷数据预处理、特征提取和负荷监测三大模块,模型结构如图 1 所示。首先获取 NILMTK 工具包,从中提取住宅内的负荷数据信息,并对各个用电设备的数据信息进行分析,丢弃负荷数据为空的记录。然后利用 VMD 将总负荷功率信号进行分解,获得若干个不同频率的有限带宽子序列,经过归一化处理,构造出各模态分量的输入输出矩阵,将其中的低频模态分量作为 CNN 的输入。最后利用 CNN 自动学习各模态数据的不同特征,对提取的特征进行非线性变化和关联识别后,分解得到不同时间段各个设备的用电负荷情况。




图1 负荷监测模型结构

Fig.1 Structure of load monitoring model

2 基于VMD的信号处理过程

VMD 是 Konstanyin Dragominetskiy 等人在 2014 年提出的新型自适应、完全非递归的模态变分和信号处理方法^[16]。该方法可以将复杂信号利用交替乘子法优化成数个频率从低到高的模态

分量(intrinsic mode function, IMF), 具有良好的时频聚集能力和较好的噪声鲁棒性^[17]。

2.1 VMD 原理

在 NILM 中, VMD 信号的特征提取过程即为获取变分问题的最优解过程。首先运用移动模态函数的频谱获得各自计算的中心频率;同时运

用高斯平滑将数据信号进行解调,取得各IMF的带宽,然后通过匹配每种IMF的最优中心频率和有限带宽,分离IMF,划分信号频域,取得信号的有效部分,最终获得变分问题的最优解。信号分解模型如下式所示:

$$\begin{cases} \min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_{k=1}^K \left\| \nabla \left[\left[\delta(t) + \frac{j}{\pi t} \right] u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \\ f(t) = \sum_{k=1}^K u_k(t) \end{cases} \quad (1)$$

式中: $u_k(t)$ 为各模态分量; ω_k 为各模态分量的中心频率; K 为分解尺度; ∇ 为梯度运算; $\delta(t)$ 为脉冲函数; $f(t)$ 为原信号; t 为时间。

为求得变分问题的最优解,引入Lagrange乘法算子 $\lambda(t)$ 和二次惩罚项 α , 将约束性变分问题转化成非约束性变分问题,增广Lagrange表达式如下:

$$\begin{aligned} L(\{u_k\}, \{\omega_k\}, \lambda_k) = & \alpha \sum_{k=1}^K \left\| \nabla \left[\left[\delta(t) + \frac{j}{\pi t} \right] u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \\ & \left\| f(t) - \sum_{k=1}^K u_k(t) \right\|_2^2 + \\ & \langle \lambda_k(t), f(t) - \sum_{k=1}^K u_k(t) \rangle \end{aligned} \quad (2)$$

采用交替方向乘子算法迭代更新 $u_k^{n+1}, \omega_k^{n+1}$, λ_k^{n+1} 的值,求得式(2)的最优解,进而分解原始负荷功率信号。首先需要将时域内的参量转换到频域内,然后在非负频域区间内,经过二次优化得到各个模态分量的表达式:

$$\hat{u}_k^{n+1}(\omega) = \frac{v + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (3)$$

式中: $\hat{u}_k^{n+1}(\omega)$ 为经过二次优化后得到的模态分量; $\hat{\lambda}(\omega)$ 为迭代更新后的乘法算子; ω 为选定的中心频率。

$\hat{u}_k^{n+1}(\omega)$ 的维纳滤波如下式所示:

$$v = \hat{f}(\omega) - \sum_{i \in R, i \neq k} \hat{u}_i(\omega) \quad (4)$$

式中: $\hat{f}(\omega)$ 为选定中心频率后得到的原始信号; $\hat{u}_i(\omega)$ 为选定中心频率后得到的模态分量。

对 $\hat{u}_i(\omega)$ 进行傅里叶逆变换取其部即可得到时域模态分量 $u_k(t)$ [18]。当用中心频率表达时,模态函数的功率谱中心表达式如下式:

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k(\omega)|^2 d\omega} \quad (5)$$

2.2 基于VMD的Hilbert变换

Hilbert变换的本质是将系统接收到的实信号还原出基带的复信号,常用来构造解析信号。首先,对负荷功率信号进行VMD分解前,需通过双阈值筛选法[19]确定分解尺度 K 的值。然后将信号 $f(t)$ 经VMD分解为 K 个固有模态分量 $u_k(t)$, 如下式所示:

$$f(t) = \sum_{k=1}^K u_k(t) \quad (6)$$

对每个模态分量 $u_k(t)$ 进行Hilbert变换,如下式:

$$H[u_k(t)] = \frac{1}{\pi} \int_{-\infty}^{+\infty} \frac{u_k(\tau)}{t - \tau} d\tau \quad (7)$$

进而构造各模态分量 $u_k(t)$ 的解析信号,如下式:

$$z_k(t) = u_k(t) + jH[u_k(t)] = \alpha_k(t) e^{j\phi_k(t)} \quad (8)$$

其中

$$\alpha_k(t) = \sqrt{u_k^2(t) + H^2[u_k(t)]} \quad (9)$$

$$\phi_k(t) = \arctan \frac{H[u_k(t)]}{u_k(t)} \quad (10)$$

式中: $\alpha_k(t)$ 为幅值函数; $\phi_k(t)$ 为相位函数。

根据解析信号可以获得幅值、相位的信息,对相位函数求导得到各IMF的瞬时频率,最终根据瞬时频谱可以得到各模态分量 $u_k(t)$ 的Hilbert谱 $H(\omega, t)$ 。

各模态分量的瞬时频率为

$$\omega_k(t) = \frac{d\phi_k(t)}{dt} \quad (11)$$

最终得到极坐标形式的解析信号实部,构成Hilbert幅值谱 $H(\omega, t)$:

$$H(\omega, t) = \text{Re} \left\{ \sum_{k=1}^K \alpha_k(t) \exp[j \int \omega_k(t) dt] \right\} \quad (12)$$

对Hilbert幅值谱进行时间上的积分得到Hilbert边际谱:

$$h(\omega) = \int_{-\infty}^{+\infty} H(\omega, t) dt \quad (13)$$

Hilbert边际谱能表明整组数据在每个频率点的累计幅值分布,与傅里叶谱相比,具有更高的频率分辨率。本文通过边际谱选定高低频的分界点 ω_i , 在某些复杂情景下,由于高频分量容易受到干扰,故而将低于 ω_i 的IMF评定为有效成分,对各IMF进行信号重构之后作为CNN的输入,如下式所示:

$$f(t) = \sum_{k=1}^i u_k(t) \quad (14)$$

2.3 结合VMD的数据预处理过程

本文使用英国UKERC能源数据中心发布的UK-DALE公开数据集作为源数据进行实验。该数据集记录了英国5个家庭的总负荷和单个负荷的电力消耗信息,其中每6 s采样一次子表信息,每6 s记录一次各个家庭的总表信息,家庭1,家庭2和家庭5每1 s记录一次有功和无功功率。基于VMD及Hilbert算法提取低频信号特征的负荷功率分解结果如图2所示。通过Hilbert时频谱可以较清晰地区分出不同频率成分的幅值在整个频段上随时间和频率的变化规律,进而有效地判断出信号中存在的主要频率成分。

由于家庭用电设备种类繁多,且各自的耗电能力不同,分解尺度的选取对于不同的设备具有不同的负荷监测影响。利用双阈值筛选法确定分解尺度 $K=4$ 时,所选取的5个用电设备负荷监测效果最好。如图2所示,总负荷功率信号经VMD分解得到5个IMF图,分解信号的采样时间为1 s。其中,IMF1为原始的功率信号;IMF2的原始功率信号的大体轮廓,表示为低频信号;IMF3的信号频率开始有所增加;IMF4则开始变得模糊,但依然保留了一定的信号特征;IMF5受噪声影响程度较大,丢失了信号的特征信息。VMD通过自适应匹配每种模态的最佳中心频率和有限带宽,实现固有IMF的有效分离、信号的频域划分、得到给定信号的有效分解成分并进行重构,获取最优解。




图2 负荷功率信号分解

Fig.2 Decomposition of load power signal

为了更好地测试网络性能,选取的用电设备包括开关型和多状态型,每种负荷具有不同的负荷特征、复杂程度以及工作周期。对家庭1中的

冰箱、洗衣机、洗碗机、微波炉和水壶进行实验,经过多次实验测得2014年6月2日上午家庭1中的冰箱、洗衣机和洗碗机存在同时运行的情况,故定为复杂情景。把实验数据分为训练集和测试集,数据选取情况如表1所示。

表1 UK-DALE数据选取信息
Tab.1 UK-DALE data selection information

设备	测试数据时间段	训练数据时间段
冰箱	2014-06-02 (08:00—20:00)	2014-07-01—2014-08-01
洗衣机	2014-06-02 (09:30—12:30)	2014-07-01—2014-08-01
洗碗机	2014-06-02 (10:30—13:00)	2014-07-01—2014-08-01
微波炉	2014-06-24 (16:30—22:30)	2014-07-01—2014-08-01
水壶	2014-06-24 (10:30—18:30)	2014-07-01—2014-08-01

3 CNN网络模型结构设计

CNN是一种具有深层结构的前馈神经网络。对比其它深度模型,其深层次的网络结构能够自动提取输入变量的关键特征,刻画输入输出之间的映射关系^[20]。

NILM是直接从聚集的负荷功率信号中监测各个用电器的电力消耗情况,故将其看为一个回归任务^[21]。CNN网络结构如图3所示,模型结构参数如表2所示。

经过多次测试,设置5个卷积层对负荷监测




图3 CNN网络结构图

Fig.3 CNN network structure

表2 卷积神经网络结构

Tab.2 Convolutional neural network structure

网络层类型	参数
卷积层1	卷积核为40,卷积核尺寸为10,激活函数为Relu
卷积层2	卷积核为50,卷积核尺寸为8,激活函数为Relu
卷积层3	卷积核为60,卷积核尺寸为6,激活函数为Relu
卷积层4	卷积核为70,卷积核尺寸为5,激活函数为Relu
卷积层5	卷积核为70,卷积核尺寸为5,激活函数为Relu
全连接层	输出个数为1 024,激活函数为Relu

的效果最佳。其中,由于下采样过程中的卷积运算会丢失特征的位置信息,且时间序列模型对数据的顺序较为敏感^[22],通过下采样会使得各设备之间的差异性被模糊化,因此,本文并未在网络结构设计中设置下采样层,而是通过平坦层把输入到神经网络之前的数据转换成一维向量,并对应到相应的神经元上。最后利用全连接层将卷积运算中提取到的特征进行非线性变化,减少特征信息的损失,获得各个设备特征之间的关系,映射到输出空间上。图3中, h 为卷积核尺寸,卷积过程表达式为

$$X^l = X_1^l \oplus X_2^l \oplus \dots \oplus X_j^l \oplus \dots \oplus X_v^l \quad (15)$$

$$X_j^l = f(X^{l-1} \otimes w_j^l + b_j^l) \quad j \in \{1, 2, \dots, v\} \quad (16)$$

式中: X^{l-1} 为输入特征; X^l 为输出特征; w_j^l 为卷积核组; $\otimes$ 为卷积运算符; $\oplus$ 为矩阵拼接运算符; j 为卷积核个数的范围; v 为卷积核个数的范围取值; b_j^l 为第 l 层第 j 个卷积核的偏置; f 为Relu函数。

卷积运算将各卷积核 w_j^l 沿着输入特征 X^{l-1} 的时间维度滑动平移,每一步对相应局部时间窗内的元素进行加权求和,再送入激活函数 f 进行非线性映射提取特征,然后将提取的各卷积核特征 X_j^l 进行矩阵拼接,得到输出特征 X^l ^[23]。

激活函数表达式如下:

$$f(x) = \max[0, \lg(1 + e^x)] \quad (17)$$

全连接层的表达式为

$$y^l = f(w^l x^{l-1} + b^l) \quad (18)$$

式中: y^l 为输出; x^{l-1} 为一维特征向量。

选取均方误差(mean square error, MSE)作为模型的损失函数,表达式为

$$MSE = \frac{1}{T} \sum_{t=1}^T (P_t - P'_t)^2 \quad (19)$$

式中: P_t 为 t 时刻设备的实际功率; P'_t 为 t 时刻设备的预测功率; T 为总时间长度。

设置批处理量的大小为512, Dropout的节点概率为0.5,利用自适应估计优化算法对网络模型进行优化。使用Dropout能够避免在训练过程中出现过拟合以及减少神经元之间复杂的共适应关系。以上设置能让每次训练有足够样本数量的同时加快训练速度,得到一个节点少且规模小的网络。

4 实验环境及算例分析

4.1 实验环境

本文的实验在 AMD Ryzen 53500x 6-core pro-

cessor(6CPU), 3.6GHz的处理器, 8GB内存, 6GB显存, Windows专业版64位操作系统上进行。使用Python 3.6.2(64)位作为软件支持平台,以Tensorflow+Keras为深度学习框架,安装GPU加速计算的CUDNN库进行网络模型的硬件加速。

4.2 实验评价指标

为了验证所提算法性能的优越性,使用平均绝对误差(mean absolute error, MAE)、相对误差(relative error, RE)、精确度(Precision)和召回率(Recall)的调和平均数(F1-score)对负荷监测结果进行性能指标评价。定义计算方法如下:

$$Recall = \frac{TP}{TP + FN} \quad (20)$$

$$Precision = \frac{TP}{TP + FP} \quad (21)$$

$$F_1 = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (22)$$

$$MAE = \frac{1}{T} \sum_{t=1}^T |P_t^{(n)} - P'_t^{(n)}| \quad (23)$$

$$RE = \frac{P_t^{(n)} - P'_t^{(n)}}{P_t^{(n)}} \quad (24)$$

式中: TP 为负荷在真实数据中打开而在预测中也是打开时的总数; FP 为负荷在真实数据中关闭而在预测中打开时的总数^[24]; FN 为负荷在真实数据中打开而在预测中关闭时的总数; $P_t^{(n)}$, $P'_t^{(n)}$ 分别为在 t 时刻设备 n 的实际功率和预测功率。

F_1 同时兼顾了模型的精确率和召回率,其数值越靠近1,表明算法的性能越好^[25]。 MAE 综合考虑每一时刻的误差对整体结果的影响。 RE 是绝对误差和真实值的比值,能在一定程度上反映测量的可信程度。

4.3 实验结果及对比分析

本文所提算法主要针对NILM精确度的提升展开研究。实验分为两个方面:

1)同一数据集同一家庭中不同负荷功率设备的实验结果评价指标方法对比;

2)同一数据集不同家庭中同种负荷功率设备的实验结果评价指标方法对比。

同一数据集同一家庭中不同负荷功率设备的实验结果如图4所示,同一数据集不同家庭中同种负荷功率设备的实验结果如图5、图6所示。

对于同一数据集同一家庭中不同负荷功率的设备,选用2014年6月2日处于同时运行中的冰箱、洗碗机、洗衣机进行实验验证,其中,冰箱的运行呈现周期性,其工作主要通过蒸发制冷和




图4 VMD-CNN负荷监测结果

Fig.4 VMD-CNN load monitoring results

气化吸热来达到制冷的目的。如图4a所示,冰箱在运行过程中功率变化频繁,幅度不一,和洗碗机、洗衣机相比,具有较小的运行功率。洗碗机和洗衣机属于多状态负荷,运行过程相对较复杂,从负荷监测结果来看,结合VMD-CNN的方法能够有效判别设备功率的起始,准确识别功率变化的时间节点,预测设备同时运行时的负荷情况。

对于同一数据集不同家庭中同种负荷功率设备,分别选用了家庭1和家庭2中使用较频繁时间段的水壶和微波炉进行实验验证。水壶属于电阻型负荷,具有整体运行时间短、使用频率高的特点。微波炉属于谐波含量较高的负荷,两种不同特性的设备在不同家庭中皆展现了较好的监测效果。为了体现本文所提方法的优势,把




图5 VMD-CNN的水壶实验结果

Fig.5 Experimental results of VMD-CNN water bottles




图6 VMD-CNN的微波炉实验结果

Fig.6 Experimental results of VMD-CNN microwave oven

以上实验结果进一步进行对比分析。其中,实验对比方法包括独立模型CNN、混合模型TCN^[24]和DANN^[26]。对于同一数据集家庭1中不同负荷的实验结果评价指标对比如表3所示。

从表3中的数据可以看出,冰箱、洗衣机和洗碗机的整体评价 F_1 分数在混合模型中更接近1,在独立的CNN模型中显得略低,考虑这是由于三种设备在同时运行过程中出现了相似波形的负荷,如图4中洗衣机和洗碗机在10:00—10:30期间出现了相似的功率波动,独立CNN模型不能进行有效判别,通过VMD进行数据预处理后输入到CNN模型中判别使得整体 F_1 分数有了较大的提升。

表3 家庭1不同负荷评价指标对比

Tab.3 Comparison of different load evaluation indexes of family 1

设备	评价指标	CNN	TCN	DANN	VMD-CNN
冰箱	MAE	26.14	4.95	8.05	5.29
	RE	0.84	0.21	0.32	0.19
	F_1	0.78	0.99	0.96	0.98
洗衣机	MAE	126.25	102.45	134.44	57.21
	RE	0.85	0.42	0.93	0.29
	F_1	0.77	0.95	0.81	0.96
洗碗机	MAE	106.21	101.06	148.04	34.17
	RE	2.64	0.73	0.81	0.53
	F_1	0.92	0.98	0.91	0.96

在混合模型对比方法中,基于VMD-CNN的方法整体 F_1 评分比DANN高,和TCN持平。其中,DANN主要通过对抗域适应来促进特征提取器提取设备的域不变特征,此方法适用于不同的家庭中,该方法在不同家庭效果稳定,具有一定的优势,但是在复杂用电场景中监测精确度有待提升。基于TCN的方法和基于VMD-CNN的方法效果相当,主要是因为TCN利用扩张因果卷积来构建特征提取器,提高了长时运行设备的精确度,这样对于短时运行设备来说并不友好。例如,对水壶来说,在开启和关闭时容易出现误判。此外,基于VMD-CNN的评价指标MAE在表3中相较其他方法均有所下降。对于同一数据集家庭1和家庭2中同一设备(微波炉和水壶)的实验结果评价指标对比如表4、表5所示。从表中数据可以看出,由于微波炉和水壶启动次数少,运行时间短, F_1 分数

表4 不同家庭微波炉评价指标对比

Tab.4 Comparison of evaluation indexes of microwave ovens in different families

家庭	评价指标	CNN	TCN	DANN	VMD-CNN
1	MAE	10.8	6.24	25.76	10.21
	RE	0.54	0.92	0.49	0.33
	F_1	0.61	0.47	0.72	0.78
2	MAE	2.39	2.88	3.45	3.56
	RE	0.31	0.14	0.29	0.24
	F_1	0.76	0.62	0.77	0.81

普遍低于表3中的洗衣机、洗碗机和冰箱。在表5中TCN的方法展示了较好的效果,然而该方法在窗口长度设置中选用综合的方式使得设备存在局限性,在表4中效果不理想。综合来看,基于VMD-CNN的方法展现了较好的稳定性和准确性,且训练时间优于DANN。

表5 不同家庭水壶评价指标对比

Tab.5 Comparison of evaluation indexes of kettles in different family

家庭	评价指标	CNN	TCN	DANN	VMD-CNN
1	MAE	27.78	27.34	95.46	14.87
	RE	0.58	0.51	1.08	0.36
	F_1	0.76	0.98	0.85	0.82
2	MAE	4.58	5.77	3.97	12.27
	RE	0.35	0.44	0.25	0.45
	F_1	0.81	0.91	0.82	0.84

综上,本文所提模型与CNN,TCN和DANN对比后所体现的优势包括:1)与CNN相比,基于VMD-CNN的方法能够有效地保留低频数据特征,降低输入信号的复杂程度,提高具有相似波形的负荷在监测过程中的准确度;2)与TCN相比,预测设备的启停状态准确度更高,设备没有局限性,相对更加稳定;3)与DANN相比,基于VMD-CNN的方法在复杂应用场景中的识别能力更强,同等迭代次数下模型训练时间更少,能够准确地分解出单个设备的负荷。

5 结论

本文提出一种基于VMD-CNN的非侵入式负荷监测方法。该方法采用VMD对负荷功率信号进行预处理,通过调整 K 的值来获取最佳分解尺度,然后利用Hilbert算法提取负荷功率信号的低频特征,并将提取的低频信号作为卷积神经网络的输入。其中,CNN模型的高分辨率恰好弥补了低频采样信号分辨率低的问题。实验仿真采用UK-DALE数据集进行验证,通过平均绝对误差、相对误差、精确度和召回率的调和平均数对负荷监测模型进行性能指标评价。同时,与独立模型CNN、混合模型TCN和DANN进行实验对比。该方法在保留原始输入负荷信号的低频特性上具有优越性,结合了VMD的网络模型抗噪能力较强,所提取的负荷特征较为丰富,并降低了输入信号的复杂度,减少了网络训练时间。对于具有不同功率的设备、处在复杂运行情景中的设备以及在具有不同用电习惯的家庭中,皆展现了较好的负荷监测性能。

参考文献

- [1] 邓晓平,张桂青,魏庆来,等.非侵入式负荷监测综述[J].自动化学报,2022,48(3):644-663.
DENG Xiaoping, ZHANG Guiqing, WEI Qinglai, et al. A survey on the non-intrusive load monitoring[J]. Acta Automatica Sinica, 2022, 48(3): 644-663.
- [2] 王孝慈,董树锋,王莉,等.基于电器状态关联分析的民可平移负荷辨识[J].电工技术学报,2020,35(23):4961-4970.
WANG Xiaoci, DONG Shufeng, WANG Li, et al. Resident shift-able loads monitoring based on load states set correlation analysis[J]. Transactions of China Electrotechnical Society, 2020, 35(23): 4961-4970.
- [3] CHEN H, WANG Y X, FAN C H. A convolutional autoencoder based approach with batch normalization for energy disaggregation[J]. The Journal of Supercomputing, 2021, 77(12): 2961-2978.
- [4] 周东国,张恒,周洪,等.基于状态特征聚类的非侵入式负荷事件检测方法[J].电工技术学报,2020,35(21):4565-4575.
ZHOU Dongguo, ZHANG Heng, ZHOU Hong, et al. Non-invasive load event detection method based on state feature clustering[J]. Transactions of China Electrotechnical Society, 2020, 35(21): 4565-4575.
- [5] 李亚前,杨滨,杨宇全,等.非侵入式负荷事件监测的曲线拟合方法[J].电力系统及其自动化学报,2021,33(5):100-105.
LI Yaqian, YANG Bin, YANG Yuquan, et al. Curve fitting method for non-intrusive load event monitoring[J]. Proceedings of the CSU-EPSA, 2021, 33(5): 100-105.
- [6] 侯艾君,王永生,顾博川,等.基于降噪滤波与FHMM的非侵入式负荷监测算法[J].自动化与仪表,2019,34(11):97-102.
HOU Aijun, WANG Yongsheng, GU Bochuan, et al. Non-intrusive load monitoring method based on denoising filtering and FHMM[J]. Automation and Instrumentation, 2019, 34(11): 97-102.
- [7] 罗平,樊星驰,章坚民,等.基于电器运行状态和深度学习的非侵入式负荷分解[J].电力系统自动化,2021,45(12):49-56.
LUO Ping, FAN Xingchi, ZHANG Jianmin, et al. Non-intrusive load decomposition based on operation state of electrical appliances and deep learning[J]. Automation of Electric Power Systems, 2021, 45(12): 49-56.
- [8] 刘耀先,孙毅,李彬,等.基于边缘嵌入深度学习的非侵入式负荷分解方法[J].电网技术,2019,43(12):4329-4336.
LIU Yaolian, SUN Yi, LI Bin, et al. Non-intrusive load disaggregation method based on edge embedded deep learning[J]. Power System Technology, 2019, 43(12): 4329-4336.
- [9] 张玉天,邓春宇,刘沅昆,等.基于卷积神经网络的非侵入负荷辨识算法[J].电网技术,2020,44(6):2038-2044.
ZHANG Yutian, DENG Chunyu, LIU Yuankun, et al. Non-intrusive load identification algorithm based on convolution neural network[J]. Power System Technology, 2020, 44(6): 2038-2044.
- [10] 杨立余,陈昊,黎明,等.非侵入式电力负荷多目标分解框架[J].电力系统保护与控制,2020,48(6):100-107.
YANG Liyu, CHEN Hao, LI Ming, et al. A framework for non-intrusive load monitoring using multi-objective evolutionary algorithms[J]. Power System Protection and Control, 2020, 48(6): 100-107.
- [11] 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.
WANG Ying, YANG Wei, XIAO Xianyong, et al. Non-intrusive residential load monitoring method based on refined identification of U-I trajectory curve[J]. Power System Technology, 2021, 45(10): 4104-4113.
- [12] 柳志军,余彬,孔锋峰,等.基于家用电器开启瞬时负荷特征的识别[J].现代建筑电气,2020,11(11):18-22.
LIU Zhijun, YU Bin, KONG Fengfeng, et al. Recognition of instantaneous load characteristics based on household appliances on[J]. Modern Architecture Electric, 2020, 11(11): 18-22.
- [13] 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 Shouxiang, GUO Luyang, CHEN Haiwen, 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.
- [14] 汪繁荣,向堃,吴铁洲.基于VMD样本熵与随机森林的非侵入式设备状态检测方法[J].现代电子技术,2021,44(15):104-108.
WANG Fanrong, XIANG Kun, WU Tiezhou. Non-invasive equipment status detection method based on VMD sample entropy and random forest[J]. Modern Electronics Technique, 2021, 44(15): 104-108.
- [15] 李莉,黄友金,熊炜,等.基于改进卷积神经网络的非侵入负荷辨识方法研究[J/OL].电测与仪表:[2021-10-10].http://kns.cnki.net/kcms/detail/23.1202.TH.20210422.1525.004.html.
LI Li, HUANG Youjin, XIONG Wei, et al. Non-intrusive load identification based on improved convolution neural network[J/OL]. Electrical Measurement & Instrumentation: [2021-10-10]. http://kns.cnki.net/kcms/detail/23.1202.TH.20210422.1525.004.html.
- [16] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.
- [17] DHANDAPANI R, MITICHE I, MALLELA V S, et al. Partial discharge signal denoising based on VMD and group-sparse TV denoising[C]/2019 2nd International Conference on Signal Processing and Information Security (ICSPIS), Dubai, United Arab Emirates: IEEE, 2019: 1-4.
- [18] 徐耀,田书,杨淇翔.综合高低频段分量的谐振接地系统故障选线[J].电力系统及其自动化学报,2021,33(10):1-9.
XU Yao, TIAN Shu, YANG Qixiang. Fault feeder detection in resonant grounding system by combining high-and low-fre-

- cy components[J]. Proceedings of the CSU-EPSA, 2021, 33(10):1-9.
- [19] 朱永利,贾亚飞,王刘旺,等. 基于改进变分模态分解和Hilbert变换的变压器局部放电信号特征提取及分类[J]. 电工技术学报, 2017, 32(9):221-235.
- ZHU Yongli, JIA Yafei, WANG Liuwang, et al. Feature extraction and classification on partial discharge signals of power transformers based on improved variational mode decomposition and Hilbert transform[J]. Transactions of China Electrotechnical Society, 2017, 32(9):221-235.
- [20] 陈达,朱林,张健,等. 基于卷积神经网络的暂态电压稳定评估及风险量化[J]. 电力系统自动化, 2021, 45(14):65-71.
- CHEN Da, ZHU Lin, ZHANG Jian, et al. Transient voltage stability assessment and risk quantification based on convolutional neural network[J]. Automation of Electric Power Systems, 2021, 45(14):65-71.
- [21] GOMES E, PEREIRA L. PB-NILM: pinball guided deep non-intrusive load monitoring[J]. IEEE Access, 2020, 8:48386-48398.
- [22] 蒙亮,于超,张希翔,等. 基于一维卷积神经网络和自注意力机制的非侵入式负荷分解[J]. 电力大数据, 2020, 23(10):1-8.
- MENG Liang, YU Chao, ZHANG Xixiang, et al. Non-intrusive load disaggregation based on 1D convolutional neural network and self-attention mechanism[J]. Power Systems and Big Data, 2020, 23(10):1-8.
- [23] 赵恺,石立宝. 基于改进一维卷积神经网络的电力系统暂态稳定评估[J]. 电网技术, 2021, 45(8):2945-2954.
- ZHAO Kai, SHI Libao. Transient stability assessment of power system based on improved one-dimensional convolutional neural network[J]. Power System Technology, 2021, 45(8):2945-2954.
- [24] 刘仲民,侯坤福,高敬更,等. 基于时间卷积神经网络的非侵入式居民用电负荷分解方法[J]. 电力建设, 2021, 42(3):97-106.
- LIU Zhongmin, HOU Kunfu, GAO Jinggeng, et al. Non-intrusive residential electricity load disaggregation based on temporal convolutional neural network[J]. Electric Power Construction, 2021, 42(3):97-106.
- [25] 赵文清,张诗满,李刚. 基于聚类和相关分析的居民用户非侵入式负荷分解[J]. 电力自动化设备, 2020, 40(6):8-14.
- ZHAO Wenqing, ZHANG Shiman, LI Gang. Non-intrusive load decomposition of residential users based on cluster and association analysis[J]. Electric Power Automation Equipment, 2020, 40(6):8-14.
- [26] 苏海军,侯坤福,高敬更,等. 基于域适应学习的非侵入式负荷分解问题研究[J]. 甘肃科技, 2021, 37(14):20-26, 66.
- SU Haijun, HOU Kunfu, GAO Jinggeng, et al. Research on non-intrusive load monitoring based on domain adaptive learning[J]. Gansu Science and Technology, 2021, 37(14):20-26, 66.

收稿日期:2021-10-31

修改稿日期:2021-12-22