

基于谐波分量与有效值的神经网络负荷分解*

蔡雨露, 聂玉虎, 崔文朋, 郑哲, 刘瑞, 池颖英

(北京智芯微电子科技有限公司, 北京 100192)

摘要: 非侵入式负荷分解可以从主表电流变化信息中分解出各个用电器的用电信息, 方便为用户提供更精细化、有针对性的用电管理和调度服务。当前利用一维卷积的非侵入式负荷分解算法存在分解准确率不高、新增用户用电器需要重新训练、复杂度较高的问题。基于此, 利用电流有效值和傅里叶变换后的谐波分量信息, 提出一种基于一维卷积神经网络的负荷分解算法, 利用相似性对比分解出各个用电器电流信息, 解决了新增用户或用电器需要重新训练的问题。经实验发现, 所提出的方法还可以在一定程度上提高负荷分解的准确率, 且复杂度较低。

关键词: 非侵入式负荷分解; 卷积神经网络; 智能电网

中图分类号: TN911

文献标识码: A

DOI: 10.16157/j.issn.0258-7998.211760

中文引用格式: 蔡雨露, 聂玉虎, 崔文朋, 等. 基于谐波分量与有效值的神经网络负荷分解[J]. 电子技术应用, 2022, 48(8): 123-126.

英文引用格式: Cai Yulu, Nie Yuhu, Cui Wenpeng, et al. Non-intrusive residential electricity load disaggregation based on harmonic components and effective value[J]. Application of Electronic Technique, 2022, 48(8): 123-126.

Non-intrusive residential electricity load disaggregation
based on harmonic components and effective value

Cai Yulu, Nie Yuhu, Cui Wenpeng, Zheng Zhe, Liu Rui, Chi Yingying

(Beijing Smart-Chip Microelectronics Technology Co., Ltd., Beijing 100192, China)

Abstract: Non-intrusive load decomposition can decompose the electricity consumption information of each consumer from the current change information of the main meter, which is convenient for providing electricity consumers with more refined and targeted electricity management and dispatching services. The current non-intrusive load decomposition algorithm using one-dimensional convolution has the problems that the decomposition accuracy is not high, the new user appliances need to be retrained, and the complexity is high. Based on this, this paper uses the effective value of current and the harmonic component information after Fourier transform to propose a load decomposition algorithm based on one-dimensional convolutional neural network, which uses similarity comparison to decompose the current information of each consumer, and solves the new problem that increasing users or using electrical appliances requires retraining. It is found through experiments that the method proposed in this paper can also improve the accuracy of load decomposition to a certain extent, and the complexity is low.

Key words: non-intrusive load decomposition; convolutional neural network; smart gridword

0 引言

非侵入式负荷监测(Non-Intrusive Load Monitoring, NILM)也称为非入侵式负荷分解(Non-Intrusive Load Disaggregation, NILD)^[1], 其通过对某一特定区域的总电表数据进行分析, 可获取该范围内各用电负荷的相关信息, 如负荷的数量、各负荷的类别、所处工作状态以及对应的能耗使用情况等^[2]。NILM可以在不入户、不对用户用电器分别安装电表的前提下, 实现对用户用电情况的监测, 通过用电行为分析更精准为用户提供相应的用电服务^[3], 对提高供电服务水平、节省电能资源、提高用电效

率等都有重要的现实意义。

1980年, Hart^[4]开创性地提出NILM的概念, 所提出的监控器在电源接口处进行测量, 基于对总负载的电流和电压的详细分析来确定在电负载中打开和关闭的单个设备的能耗。这种方法可以将用电器从少量电器种类中分解出来, 对于用电器种类较多的情况下, 则很难准确地进行分解。因此, 后续不断有学者提出通过增加不同负荷特征的方式改进分解效果。负荷特征主要包括有稳态特征、暂态特征、周期性特征状态转换特征, 其中暂态特征又可以细分为暂态功率波形特征、电压噪声特征等, 稳态特征细分为功率的阶跃特征、稳态电流波形特征等^[5]。通过研究发现, 通过提取更多特征的方式进行

* 基金项目: 国网科技项目(5700-202016489A-0-0-00)

负荷分解取得了良好的分解效果。

近几年来,深度学习开始在负荷分解中得到应用。利用神经网络的方法,避免了手动设计特征,且更容易分析时间序列特征,在分解准确率方面也有一定的提高^[5-8]。目前,深度学习在非侵入式负荷分解应用上的研究是现在的重要方向之一。

本文是基于电参量的稳态特征与谐波分量特性,利用一维卷积神经网络的方法,对家用多用电器进行分解。不仅可以准确地分解出所需用电器,还可以通过针对不同用户家庭进行用电器信号库的补充,不再进行重复训练即可达到良好的分解效果。

1 非侵入式负荷分解

非侵入式负荷监测是典型的时间序列分析问题^[2]。在某个时间 t ,非侵入式负荷分解可以表示为:

$$F(p_i)=[P^1(t), P^2(t), \dots, P^N(t)]+[e^1(t), e^2(t), \dots, e^n(t)] \quad (1)$$

其中, p_i 为 t 时刻电表采集到的所有用电器的总功率; $P^n(t)$ 为 t 时刻用电器 n 的预测功率值; $e^n(t)$ 是用电器 n 实测值与预测值的误差。

典型的非侵入式负监测流程包括数据采集、数据预处理、负荷分解等步骤^[9],如果是采用深度学习的方法进行分解,还需要搭建网络模型和对神经网络进行训练的步骤。具体步骤如图 1 所示。

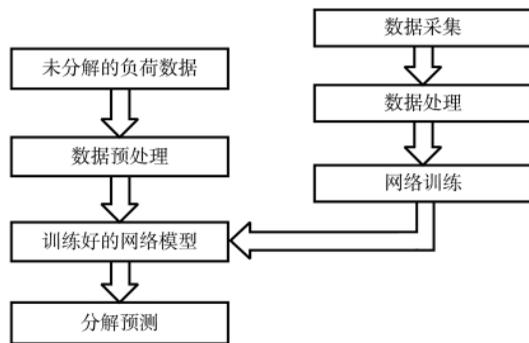


图 1 负荷分解示意图

1.1 非侵入式负荷分解模型输入电参量

负荷特征是进行负荷分解的重要因素,主要是对电压、电流、电功率进行特征变化,形成利于提取特征的电参数。

1.1.1 电流有效值

交流电流的大小和方向会随时间作周期性变化,假设交流电为 I ,则交流电的有效值为:

$$I = \frac{I}{\sqrt{2}} \quad (2)$$

1.1.2 谐波分量

谐波分量是指一个周期内的电气量的傅里叶级数中次数大于 1 的整数倍分量。

假设采集到的电流可用正弦函数 $y=A\sin(\omega x+\varphi)$ 表示,

则其傅里叶级数可以写成如下公式:

$$f(t) = \frac{a_0}{2} + a_1 \cos(\omega t) + b_1 \sin(\omega t) + a_2 \cos(2\omega t) + b_2 \sin(2\omega t) + \dots$$

$$= \frac{a_0}{2} + \sum_{n=1}^{\infty} [a_n \cos(n\omega t) + b_n \sin(n\omega t)] \quad (3)$$

其中, a_n 、 b_n 就是谐波分量。

$$a_n = \frac{2}{T} \int_{t_n}^{t_n+T} f(t) \cos(n\omega t) dt \quad (4)$$

$$b_n = \frac{2}{T} \int_{t_n}^{t_n+T} f(t) \sin(n\omega t) dt \quad (5)$$

1.2 基于有效值和谐波分量的负荷分解模型

本文与现有的非侵入式负荷分解模型算法的重要区别在于数据选取的不同。有学者利用用户用电器工作模式的差异,通过不同用电器工作时间的差异进行分解^[10-11]。但是由于多种用电器工作模式过多,更是能够排列组合出成千上万种工作模式,因此分解效果不佳。

另一种可供选择的数据是通过电流的有效值进行分解。由于用电器开始工作时电流有效值会产生跳变沿,不同用电器有不同大小的电流有效值跳变,因此,可以借助于此跳变沿的不同进行分解。采用这种数据可以有效获取有用信息,但数据信息量还不够足,分解可供参考的值过少,容易产生错误分解。

基于前人的经验,在有效值后又加入高频谐波分量,作为整体的数据进行负荷分解的相似性比对。高频分量往往拥有更多的有效信息,且不同用电器在跳变沿有不同的高频谐波分量数据,根据某一时刻前后的谐波分量差来判断具体是哪一用电器发生工作模式的变化。

本文对一次周期的电流量进行采样,采样周期为 20 ms/次。假设 I_n 为第 n 次采样得到的有效值, I_n 为第 n 次采样得到的谐波分量,则本文针对的数据 Y 可表示为:

$$Y = [I_1 + I_2 + \dots + I_n] + [I_1 + I_1 + \dots + I_n] \quad (6)$$

1.3 负荷分解评价指标

非侵入式负荷分解涉及多个步骤,任何步骤都会影响到最终的分解效果。主要评价指标有以下几个方面:

(1) 负荷分解的结果准确率。

负荷分解识别准确率主要指标有:

① 平均绝对误差 (Mean Absolute Error, MAE), 用来评估在某个时刻分解效果的好坏。假设 g_t 为某个电器在 t 时刻真实消耗的功率, P_t 为经过负荷分解分解出的某个用电器功率。

$$MAE = \frac{1}{T} \sum_{t=1}^T |P_t - g_t| \quad (7)$$

② 综合信号误差 (Signal Aggregate Error, ASE), 用来评价一段时间内的分解效果好坏。

$$SAE = \frac{P - P^*}{P} \quad (8)$$

式中, P 表示为一段时间内的功率消耗值, P^* 为负荷分解后在一段时间内的功率消耗。

(2)识别效果的稳定性。

(3)识别算法的泛化能力和可扩展性。

2 基于一维卷积神经网络的负荷分解

2.1 卷积神经网络

卷积神经网络(Convolutional Neural Network, CNN)是一种由卷积层、池化层、全连接层组成的多层监督学习神经网络,如图2所示。其中,卷积层用来提前特征信息;池化层用来进行下采样,减少数据量的同时尽可能地保留有效的特征;全连接层得到激活后的特征信息值。与其他深度神经网络相比,卷积神经网络有共享的特征,能够简化网络结构的同时有更好的适应性,能够实现分类和识别任务^[12]。

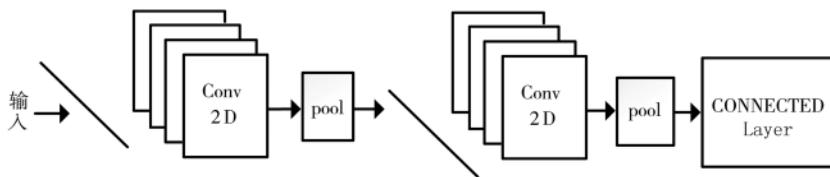


图2 卷积神经网络结构图

2.2 一维卷积神经网络

一维卷积神经网络(1D Convolutional Neural Network, 1D-CNN)是一种能够从时间序列中提取时间特征的卷积神经网络^[13]。

一维卷积的输入输出是一个向量,卷积核在一维空间进行滑动,经过向量和卷积核的运算输出另一个向量,如图3所示。

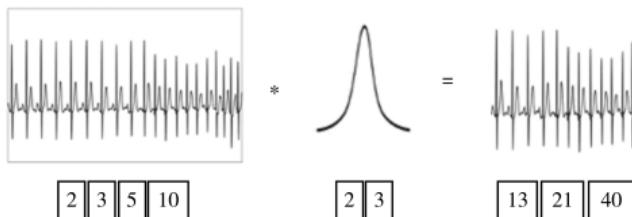


图3 一维卷积运算示意图

本文利用一维卷积进行特征提取,由于数据量不大,为了更好地保证数据的特征,去掉池化过程,直接在卷积层后跟全连接层,提高特征准确度。

2.3 非入侵式负荷分解网络模型

如图4所示,本文采用的一维神经网络结构为5层卷积层和1层全连接层。

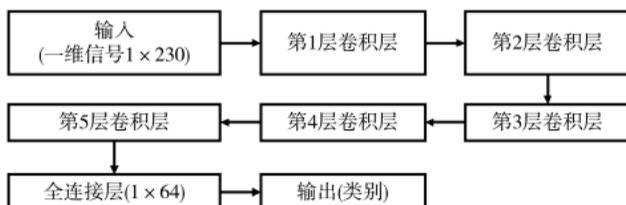


图4 本文采用的负荷分解网络结构图

输入信号是 1×230 大小的一维信号,由某一时刻的电流有效值和谐波分量组成。

在推理过程中,通过对64 bit 数据特征进行相似性比对来最终判断属于哪一类别。

3 实验

3.1 数据采集

采集数据是进行负荷分解的第一步。目前,电力公司所能够采集到的数据主要包括:电流、电压、电功率和频率,这些基本物理参数通过简单计算可获得有功功率、功率因数、无功功率、有效值、谐波分量及能耗等设备参数^[14]。

本实验过程中,采用Blued数据集,数据集包含大约8天之内来自单个美国家庭的高频(12 kHz)家庭级数据。每秒包括60个周期,每个周期有15000个采样点,以得到电流的正弦波形,不同用电器的波形如图5所示。图6、图7分别给出空调和热水壶的跳变沿波形图,通过此可以计算出电流的有效值以及谐波分量。

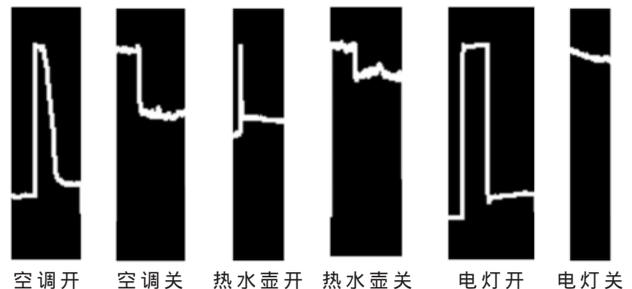


图5 不同用电器跳变沿



图6 空调谐波分量



图7 热水壶谐波分量

3.2 实验结果分析

一维神经网络的输入是电流有效值加谐波分量组

成的一维数组;输出为电器类别。对 Blued 数据进行了处理,得到的处理后的数据维度为'labels.npy':(338,4,53);'dataset.npy':(338,4,1,230,1)。将以上数据维度展开,得到 1 352 条维度为 230 的数据,其中每条数据的前 9 维为电器投切发生前后的频域特征向量之差,后 221 维为投切过程中相关电流或电压信号的变化情况(跳变沿)。

1 352 条数据中第一类和第二类占了绝大多数,两者之和占比超过 88%。前 20 类中,每类包括的数据条数分别为:901,295,11,7,71,9,9,4,1,1,2,1,0,1,1,1,0,1,1,1。将第一类和第二类数据拿出来作为单独一个数据集,进行二分类模型的训练,准确度可达 80%以上,其中利用前 9 维数据训练模型的准确率略高,为 82.22%;利用后 221 维数据训练模型的准确率为 81.11%。

将第 1,2 和 5 类数据分别作为一类,剩余所有数据作为一类,建立一个 4 类别的数据集。利用前 9 维数据训练模型的准确率约为 67.98%,利用后 221 维数据训练模型的准确率为 69.46%。

4 结论

本文针对电流采样数据得到的电流有效值和谐波分量,利用 1D-CNN 构建非侵入式负荷分解模型,并获得了很好的分解效果,所得到的训练模型具有很好的扩展性和泛化能力。具体特点总结如下:

- (1) 获取实验数据(电流有效值+谐波分量);
- (2) 针对性构建 1D-CNN 模型;
- (3) 根据用户电器情况,无需重新训练,针对性调整推理数据集即可。

最后,通过实验结果分析可知,采用本文方法的分解准确率达到 95%。且相对于传统的神经网络方法,避免了频繁的训练过程,为有针对性地进行负荷分解节省时间。

参考文献

- [1] 王琪凯,熊永康,陈瑛,等.基于 Attention 机制优化 CNN-seq2seq 模型的非侵入式负荷监测[J/OL].电力系统及其自动化学报:1-9[2022-07-06].DOI:10.19635/j.cnki.csu-epsa.000997.
- [2] 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.
- [3] 余贻鑫,刘博,栾文鹏.非侵入式居民电力负荷监测与分解技术[J].南方电网技术,2013,7(4):1-5.
- [4] HART G W.Nonintrusive appliance load monitoring[J].Pro-

ceedings of the IEEE,1992,80(12):1870-1891.

- [5] 葛维春,沈力,耿博文,等.一种基于阶跃特性的空调负荷参与的电网日前调度方法[P].中国:CN108039710A,2018-05-15.
- [6] CHANG H, LIAN K, SU Y, et al.Power-spectrum-based wavelet transform for nonintrusive demand monitoring and load identification[J].IEEE Transactions on Industry Applications,2014,50(3):2081-2089.
- [7] 郑义林,刘永强,梁兆文,等.改进最小二乘变点识别法在负荷分解的应用[J].计算机测量与控制,2019,27(6):226-230.
- [8] ZHANG C Y, ZHONG M J, WANG Z Z, et al.Sequence-to-point learning with neural networks for non-intrusive load monitoring[J].arXiv Preprint arXiv:1612.09106v3,2017.
- [9] 郑义林.基于深度时间卷积网络的非侵入式负荷分解[D].广州:华南理工大学,2020.
- [10] 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.
- [11] 江泽昌,刘天羽,江秀臣,等.智能电网下多时间尺度家庭能量管理优化策略[J].太阳能学报,2021,42(1):460-469.
- [12] Chen Kunjin,Zhang Yu,Wang Qin,et al.Scale- and context-aware convolutional non-intrusive load monitoring[J].IEEE Trans. on Power Systems,2020,35(3):2362-2373.
- [13] 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.
- [14] SIMPSON C D.Principles of electronics[M].Upper Saddle River:Prentice Hall,1996:85-102.

(收稿日期:2021-05-16)

作者简介:

蔡雨露(1994-),通信作者,女,硕士研究生,初级工程师,主要研究方向:深度学习、机器学习、集成电路,E-mail:caiyulu@sgechip.sgcc.com.cn。

聂玉虎(1991-),男,硕士研究生,工程师,主要研究方向:深度学习、机器学习。

崔文朋(1987-),男,硕士研究生,高级工程师,主要研究方向:微电子学、人工智能。



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