

基于 CNN-BiGRU-Attention 的非侵入式负荷分解

任智仁¹, 汤博¹, 周弼¹, 薛雷¹, 易灵芝², 刘西蒙²

(1. 威胜集团有限公司, 湖南长沙 410129;

2. 湘潭大学自动化与电子信息学院, 湖南湘潭 411105)

摘要: 随着智能电网的迅速发展, 为了有效提高电能的使用率, 合理规划电能资源, 建立全国范围内的智能用电和负荷监测系统, 非侵入式负荷监测(NILM)和分解问题一直受到广泛关注。为提高非侵入性负荷分解性能, 提出一种基于耦合神经网络的非侵入式负荷分解方法。首先, 对数据集进行归一化和预处理。其次, 构建一种将卷积神经网络(CNN)与双向门控循环单元(BiGRU)相结合的混合深度学习模型, 对数据的空间特性和时序特性进行充分挖掘, 并加入注意力机制, 关注重要信息, 剔除冗余特征。最后, 采用国内自测数据集进行试验, 使用不同的评价指标对该耦合神经网络进行评估, 并与其他常用的分解模型进行对比。试验结果表明, 所提方法的均值绝对误差与绝对误差和相较于其他分解方法都有所降低, 均值绝对误差平均下降了 35.9%, 绝对误差和平均下降了 39.9%。

关键词: 非侵入式负荷分解; 卷积神经网络; 双向门控循环单元; 注意力机制

中图分类号: TM714 文献标志码: A 文章编号: 1673-6540(2022)08-0041-06

doi: 10.12177/emca.2022.080

Non-Intrusive Load Disaggregation Based on CNN-BiGRU-Attention

REN Zhiren¹, TANG Bo¹, ZHOU Bi¹, XUE Lei¹, YI Lingzhi², LIU Ximeng²

(1. Wasion Group Co., Ltd., Changsha 410129, China;

2. College of Automation and Electronic Information, Xiangtan University, Xiangtan 411105, China)

Abstract: With the rapid development of smart grid, the problem of non-intrusive load monitoring (NILM) and disaggregation has been widely concerned in order to effectively improve the utilization of power, rationally plan the power resources, and establish the nationwide smart power and load monitoring system. To improve the performance of non-intrusive load disaggregation, a non-intrusive load disaggregation method based on coupled neural network is presented. Firstly, the dataset is normalized and preprocessed. Secondly, a hybrid deep learning model is constructed, which combines convolution neural network (CNN) with bidirectional gated recurrent unit (BiGRU). The spatial and temporal characteristics of data are fully explored, and attention mechanism is added to focus on important information and eliminate redundant features. Finally, the domestic self-test data set is used for the experiment, and the coupled neural network is evaluated with different evaluation indexes, and compared with other commonly used disaggregation models. The experimental results show that the mean absolute error and sum of absolute error of the proposed method are reduced compared with other disaggregation methods, the mean absolute error is reduced by 35.9% and the sum of absolute error is reduced by 39.9% on average.

Key words: non-intrusive load disaggregation; convolutional neural network (CNN); bidirectional gated recurrent unit (BiGRU); attention mechanism

收稿日期: 2022-05-30; 收到修改稿日期: 2022-07-14

作者简介: 任智仁(1977—), 男, 学士, 高级工程师, 研究方向为电力系统继电保护、智能电能表计量算法及非侵入式负荷识别、电力人工智能。

易灵芝(1966—), 女, 教授, 研究方向为交流调理与电力装置、新能源发电、智能微网技术等。

0 引言

非侵入式负荷监测(NILM)也称负荷分解,通过一定区域内总功率数据分析出各个负荷的相关信息,进而通过分析得到的数据了解用户的用电习惯以及各设备能耗的具体情况。在用户用电舒适情况下,对用户的可控负荷进行优化调度,实现节能降耗,节省电费开支^[1]。

NILM 最早由 Hart^[2] 提出,之后,国内外便兴起了对 NILM 领域的相关研究。文献[3]利用低频数据基于因子隐马尔可夫模型(FHMM)的非侵入式负荷分解方法,将负荷分解转化为概率最大的优化问题。文献[4]设计了一种基于稳态分割的事件检测器和一种基于多特征全局相似度的线性判别分类器组,利用综合特征对一个周期内的独立未知电器的功耗曲线进行分解,但分解的准确率较低。文献[5]提出新的负载分解方法功率签名符号,同时利用状态机来检测设备的开关状态,机器学习用来识别设备,但该方法需要提前获取设备信息。

近年来,深度学习在语音识别^[6]、图像识别^[7]、自然语言^[8]处理等方面取得了优异的识别效果,具有计算复杂度固定以及不需要人工提取特征的优势。深度学习网络模型得到了迅速发展,应用在非侵入式负荷分解中,大大提高了分解准确度。文献[9]提出一种基于图信号处理的非侵入式分解方法,但是分解的速度较慢。文献[10]通过卷积深度神经网络识别设备的激活状态,不仅可以识别家用电器的激活状态,还能估计消耗从而获得高性能。文献[11]为提高分解模型的准确率,提出了一种复合的深度长短期记忆(LSTM)网络的负荷分解方法,该方法提高了分解的效率和事件检测的综合性能。文献[12]研究了注意力机制对负载分解的影响,并将注意模块添加到常用的负载分解模型中,将负载分解问题转化为求解最优组合的过程。文献[13]采用了一种基于深度学习的有效且适用的解决方案。该方法采用层对层结构,提取各家电的功耗曲线特征,能够检测和区分电器的类型,提高了分解的准确度和分解速度。文献[14]提出了基于批量规范化和爬山算法的卷积神经网络(CNN)自编码器,通过公共数据集 redd 验证了有效性。

本文对 CNN 模型进行改进,提出了将 CNN 与双向门控循环单元(BiGRU)相结合的混合深度学习模型,进一步提取输入序列的空间特性和时间特性,并且加入了注意力机制,提取有利特征,丢弃无用特征,不仅有效减少了训练时间而且显著提升了非侵入式负荷分解的准确率。最后采用国内自测数据集进行试验,试验结果表明,该方法能够取得较为优异的分解性能。

1 非侵入式负荷分解模型

1.1 非侵入式负荷分解原理

非侵入式负荷分解以功率为研究对象,所探讨的内容涉及时序分析。以分解一户家庭在某一时刻的总表功率为例,该时刻投入使用的所有负荷所消耗的功率决定总表功率。简而言之,假设有 M 个只有简单投切二状态的负荷与总电表相连,并且设备投入时所消耗的功率保持不变,则时刻 t 下的总表功率可表示为

$$P(t) = \sum_{m=1}^M a_m(t) P_m + e(t) \quad (1)$$

式中: $a_m(t)$ 表示设备 m 在 t 时刻的状态,如果设备 m 在 t 时刻处于工作状态,则 $a_m(t) = 1$, 否则 $a_m(t) = 0$; P_m 表示设备 m 处于工作状态时的功率; $e(t)$ 表示噪声或误差量。

在时刻 t 下,如果单个电器的功率 P_m 得以确定,且同一时刻的总表功率 $P(t)$ 也确定,则非侵入式负荷分解可用优化问题来代替,即在每一个时刻 t , 遍历 M 向量 $\hat{\mathbf{a}}(t)$, 并使其达到最小,用公式表示为

$$\hat{\mathbf{a}}(t) = \arg \min_{\mathbf{a}_m \in \{0,1\}} \left| P(t) - \sum_{m=1}^M a_m(t) P_m \right| \quad (2)$$

1.2 Seq2Seq 学习模型

本文在编码-解码部分采用 Seq2Seq 模型。常见的 Seq2Seq 模型使用循环神经网络(RNN)进行编码和解码。但是,由于 RNN 结构复杂、训练参数多,容易造成梯度爆炸、梯度消失、训练速度慢等问题。为了解决这些问题,本文在编码部分采用 CNN,提高了模型的训练速度,在解码部分采用 BiGRU。BiGRU 是 LSTM 的变体,可以有效地提取时间特征解决梯度消失问题,减少参数数量,提高训练速度。Seq2seq 模型使用一个滑动窗口大小作为一层神经网络的输入,根据不同的负

荷类型设定不同的窗口大小,将每个时刻输出的窗口预测值的平均值作为预测结果。试验结果表明,该方法可以更好地提取特征,减少消耗的时间。

2 网络介绍

2.1 CNN

CNN 属于典型前馈神经网络,包括输入层、隐藏层、输出层,其本质是通过建立多个滤波器提取输入数据的特征。这些滤波器对输入数据进行逐层卷积和池化,层层提取蕴含在输入数据中的拓扑结构特征。其中隐藏层又可分为卷积层、池化层与全连接层。卷积层可通过不断地迭代模型参数获取最优卷积核,并对卷积核进行自动特征提取。池化层通过在时间层次上的降维操作抽取最重要的特性。常用的池化操作有最大值池化、平均池化。卷积层和池化层的堆积产生深度网络结构,再通过逐层抽象化获得更高级的特性。通过卷积层与池化层处理,将输出数据通过全连接层映射至分类标记空间,最后将全连接层的输出用 Softmax 函数转换为分类标记。

2.2 BiGRU 神经网络

RNN 和普通前馈神经网络的不同之处在于将输入的时序类型信息纳入考虑,常用于语音识别和图像分类等领域。为了解决 RNN 中的梯度消失问题, Hochreite 和 Sshmidhuber 提出 LSTM。LSTM 由多个相同的细胞结构构成,每个细胞结构由遗忘门、输入门、输出门组成。LSTM 网络参数过多,导致模型的速度慢、效率低。因此,通过将 LSTM 中的输入门和遗忘门合并为更新门,衍生出了收敛速度更快的门控循环单元。

门限回归单元(GRU)就是 LSTM 的一种变体,其细胞结构如图 1 所示。GRU 具有 2 个控制门单元,分别是重置门和更新门,去除了记忆单元,减少了参数,提高了模型的计算速度。GRU 的单位神经元通过更新门和重置门来处理上一时刻输出的信息,更新门处理上一时刻的信息,重置门移除上一时刻的无用信息。

BiGRU 在 GRU 的基础上改进了结构,其由两层 GRU 组成,一层正向传播,一层反向传播,最终将两层的输出结果进行拟合得到分解结果,提高模型的分解精度,其网络结构如图 2 所示。




图 1 GRU 基本结构图




图 2 BiGRU 网络结构图

2.3 注意力机制

注意力机制类似于大脑对物体的观测模式,当处理接受到的信息时,将目光聚焦于重点地方。注意力机制采用了分配信息权重的方法,筛选重要信息,舍弃无用信息。将注意力机制导入神经网络中,就能够降低干扰信息,从而提升模型的性能,具体结构如图 3 所示。其中, $x_1 \sim x_n$ 为预测模型的输入; $h_1 \sim h_n$ 为每一个输入对应的隐藏层的输出; $\alpha_1 \sim \alpha_n$ 为每个隐藏层输出的注意力概率分布值; y 为经过注意力机制处理后的模型输出值。




图 3 注意力单元结构图

3 基于 CNN-BiGRU-Attention 的非侵入式负荷分解

3.1 非侵入式负荷分解流程

本文采用有功功率作为研究对象,通过对原始数据进行数据处理,划分数据集。使用滑动窗口将输入电力数据进一步处理成相同尺寸的数据,同时将总功率序列和单个电器序列输入深度学习网络模型进行训练,得到单个模型的预测值,通过 Adam 优化器对输出的损失值进行参数优

化,不断调节模型参数,进一步优化模型。最后将测试样本中的总功率数据,输入训练好的模型中即可得到网络的输出,即单个目标电器的消耗功率。非侵入式负荷分解流程图如图4所示。




图4 非侵入式负荷分解流程图

3.2 数据处理

训练网络模型需要大量的数据,然而测量大量数据需要投入很多时间成本,为了解决这个问题,本文使用原始数据去构造训练数据,使用大量的训练数据训练分解模型,提高分解模型的性能。具体步骤如下:

(1) 选取一种用电器作为主电器,根据主电器深度学习模型的输入序列长度构建输入序列两倍大小的全零序列,其中主电器的输入序列长度由其激活状态的长度决定。若用电器有多个激活状态,选取激活状态最长序列构建全零序列。

(2) 任意选取主电器的一次负荷激活状态,并且保证该激活状态可以完整放入新建的全零序列之中。除此之外,在50%的概率下,放入主电器的激活状态。

(3) 任意选取其他非主电器的一次负荷激活序列任意起点叠加其中,并且非主电器序列的叠加以25%的概率即可。

(4) 重复(1)~(3),得到N条数据的测试集。

3.3 分解模型

分解模型如图5所示,输入是有功功率序列,通过多层CNN对输入序列进行编码,提取输入序列的空间特性。然后再经过BiGRU进行解码,进一步提取时间特性,由于功率数据是一种典型的时间序列信息,BiGRU在对其进行学习时采用双层循环单元,并借鉴“跨层连接”的思想,将前后特征进行组合复用输出到多个负荷分支,减少大量的参数,提高了训练速度,节约计算成本,加强了网络对用电数据的表征能力。同时引入注意力

机制,关注重要信息,剔除冗余信息,提高了分解模型的准确度。该分解模型具有较强的负荷分解能力。

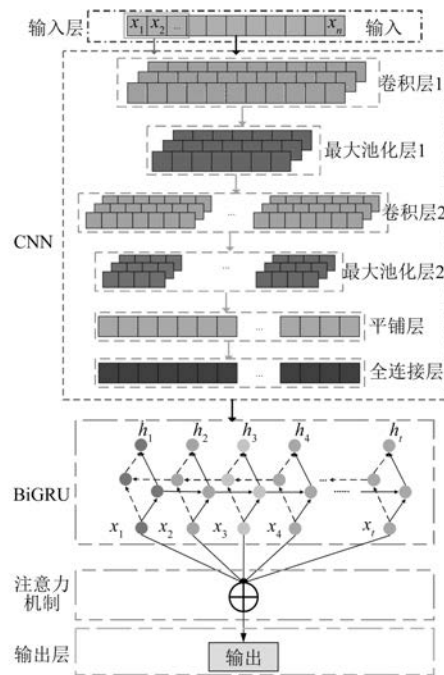


图5 分解网络结构

3.4 分解模型网络参数

对网络分解性能及训练时长综合衡量,网络结构及对应参数设置如表1所示。在对网络进行训练时,将Batchsize设置为256,迭代次数设为50,激活函数采用Relu,学习率为0.001,优化策略采用Adam优化器。

表1 网络结构与对应参数

网络	输入维度	输出维度	维度	激活函数
CNN	(256,1)	(256,16)	16 * 1	Relu
CNN	(256,16)	(256,16)	16 * 1	Relu
Bi-GRU	(256,16)	(256,128)	-	Relu
Bi-GRU	(256,128)	(256)	-	-

4 算例分析及结果

本文采用国内自测数据集进行试验,数据集包含3个总表数据,每个总表数据下含有3个用电器,数据集的采样频率为1s,即每1s采样一个功率点。

4.1 硬件环境及软件平台

本文采用的硬件环境为内置Window10操作

系统和 16 G 内存的 64 位计算机, 软件使用 python3.7。

4.2 负荷分解评价指标

为了对所提模型进行负荷分解性能评估, 本文选取其中两类评估指标, 即均值绝对误差 (MAE) 与绝对误差和 (SAE), 以此对模型进行评估。相关计算公式如下:

$$MAE = \frac{1}{T} \sum_{i=1}^T |\hat{x}_i - x_i| \quad (3)$$

$$SAE = \frac{|\hat{e} - e|}{e} \quad (4)$$

式中: x_i 为 t 时刻, 家用电器的实际量测值; \hat{x}_i 为 t 时刻, 家用电器的预测值; $e = \sum_{i=1}^T x_i$ 表示家用电器的实际能耗; $\hat{e} = \sum_{i=1}^T \hat{x}_i$ 表示家用电器的预测能耗。

4.3 结果分析

本小节采用的数据为国内 3 个家庭的总表数据及其对应的分表数据, 具体为: 总表 1 对应的分表为微波炉、水壶、电饭煲; 总表 2 对应的分表为电磁炉、电饭煲、微波炉; 总表 3 对应的分表为电磁炉、电饭煲、空调。

本小节将 FHMM、组合优化算法 (COA)、去噪自动编码器 (DAE)、LSTM 作为对比模型, 试验结果对比如表 2、表 3 所示。

分析表 2 和表 3 可知, 相较于其他算法, FHMM 和 COA 的 MAE 和 SAE 较高, 而深度学习算法相较于前者 MAE 和 SAE 有所降低, 相较于传统的神经网络, 本文模型性能有较为显著的提高。本文模型对电磁炉、电饭煲、微波炉 3 种电器的 MAE 和 SAE 的值降低明显, 表明该模型具有良好的分解效果。

表 2 不同算法的 MAE 对比

表类	电器名称	MAE				
		FHMM	COA	DAE	LSTM	本文模型
总表 1	微波炉	36.679	28.843	17.952	24.754	13.923
	水壶	32.867	29.762	15.829	28.327	13.050
	电饭煲	64.763	53.476	47.813	67.275	49.729
总表 2	电磁炉	24.647	19.825	16.793	13.971	7.529
	电饭煲	43.566	53.764	36.476	48.435	32.243
	微波炉	23.572	36.859	17.015	14.773	10.511
总表 3	电磁炉	34.331	21.145	18.122	14.096	11.926
	电饭煲	26.120	38.323	24.678	36.085	14.409
	空调	59.115	67.521	48.185	43.287	36.480

表 3 不同算法的 SAE 对比

表类	电器名称	SAE				
		FHMM	COA	DAE	LSTM	本文模型
总表 1	微波炉	0.967	1.728	0.679	0.359	0.277
	水壶	0.273	0.809	0.010	0.017	0.003
	电饭煲	1.004	2.907	0.780	0.165	0.059
总表 2	电磁炉	0.042	0.664	0.036	0.019	0.014
	电饭煲	2.528	1.277	1.364	0.027	0.036
	微波炉	1.769	2.341	0.037	0.115	0.011
总表 3	电磁炉	0.240	0.376	0.013	0.010	0.009
	电饭煲	1.031	1.044	0.159	0.270	0.039
	空调	0.214	0.587	0.071	0.029	0.026

由表 2 和表 3 数据可知, 本文模型对总表下的大部分电器能够取得较为优异的分解效果, 其对于总表对应下的各类电器分解图如图 6~图 8 所示。由图 6~图 8 可以看出, 本文模型不仅对于真实值的拟合效果较好, 而且分解的准确度较高。对水壶的分解在部分时间区域出现了偏差, 但是分解的功率值仍较为准确。




图 6 总表 1 对应的各类电器分解图




图7 总表2对应的各类电器分解图

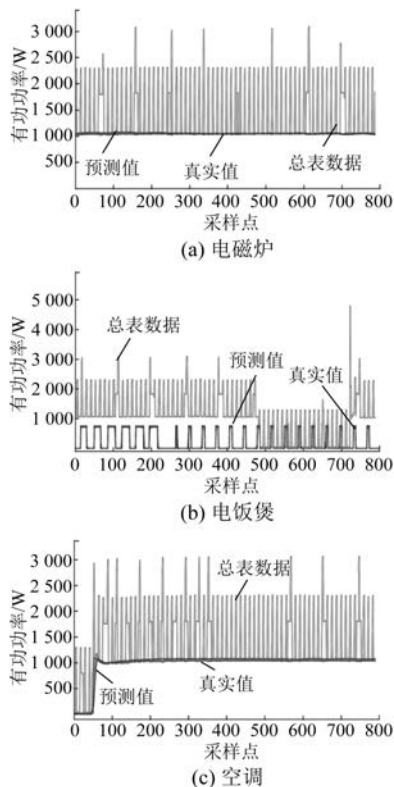


图8 总表3对应的各类电器分解图

同时由表4的模型训练时间对比可知,相比于其他分解算法,本文所提的方法可以减少模型训练时间,使模型学习训练更加快捷高效。

表4 模型训练时间对比 min

模型	COA	DAE	LSTM	本文模型
耗时	101	78	44	32

5 结 语

为进一步提升负荷辨识的准确率,通过 CNN 对输入功率序列进行空间特征提取,将其作为 BiGRU 的输入,通过 BiGRU 进一步提取其时间特性,并且引入注意力机制,使该模型更加关注重要特征,剔除干扰因素,提高模型分解的准确度。为验证所提方法的优越性,在国内自测数据集上进行试验。对比结果表明,本文所提非侵入式负荷分解模型比其他算法更佳,该模型降低了 MAE、SAE,其分解算法的准确率比其他算法更高。相关结论如下:

(1) CNN 与 BiGRU 相结合的混合深度学习模型,对数据的空间特性和时序特性进行充分提取,提高了模型的分解准确度。

(2) 注意力机制的引入使神经网络在对于某些特征向量的识别中具有良好的补足效用,使模型更加关注重要部分,剔除不必要的因素,提高了其分解性能。

(3) 在进行实际负荷监测时,所提算法具有较好的分解性能,能够很好地应用于实际用电场景。

【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.
 [2] HART G W. Nonintrusive appliance load monitoring [J]. Proceedings of the IEEE,1992,80(12):1870.
 [3] YANG C H, WU Z S. Research on non-intrusive load decomposition based on FHMM [J]. IOP Conference Series: Materials Science and Engineering, 2020,768(6):062046.
 [4] YU J, GAO Y, WU Y, et al. Non-intrusive load disaggregation by linear classifier group considering multi-feature integration [J]. Applied Sciences, 2019,9(17):3558.

(下转第 52 页)