

# 基于改进子任务门控网络的非侵入居民负荷分解

郭艳霞,徐正一,琚 赞

(华北电力大学,北京 102200)

## Non-intrusive residential load disaggregation based on advanced SGN

GUO Yanxia, XU Zhengyi, JU Yun

(North China Electric Power University, Beijing 102200, China)

**摘要:**非侵入负荷分解对挖掘用户侧能源需求具有重要意义。但是,目前功率分解模型收敛困难且推理周期计算量大。研究了基于序列到子序列和子任务门控网络(SGN)的非侵入负荷分解模型。首先,采用序列到子序列的方法构建子任务门控网络,将功率分解回归任务和电器状态分类任务相结合,实现主电源序列到目标电器子序列的映射;然后添加通道注意力模块和空间注意力模块提高模型的特征提取能力。基于UK-dale数据集的实验结果表明,该方法不仅减小了模型收敛的困难度和推理周期的计算量,而且显著提高了分解的精度。

**关键词:**非侵入负荷分解;子任务门控网络;空间注意力;通道注意力

**Abstract:** Non-intrusive residential load disaggregation is of great significance for mining the energy demand on the user side. However, the current power decomposition model does not converge well and the inference cycle is computationally intensive. A non-intrusive load decomposition model based on sequence-to-subsequence and subtask gated networks (SGN) is investigated in the paper. Firstly, a sequence-to-subsequence approach is used to construct a sub-task gating network, combining a power decomposition regression task with an appliance state classification task to achieve a mapping from the main power sequence to the target appliance sub-series. Then a channel attention module and a spatial attention module are added to improve the feature extraction capability of the model. Experimental results based on the UK-dale dataset show that the method not only reduces the difficulty of convergence of the model and the computational effort of the inference cycle, but also significantly improves the accuracy of the decomposition.

**Key words:** non-intrusive load disaggregation; SGN; spatial attention; channel attention

## 0 引言

非侵入式负荷监测技术(non-intrusive load monitoring, NILM)指通过在用户进户总线处设置传感器,获取家用电器的聚合信息,然后计算得到目标电器的负荷电量以及负荷模式,有利于用户合理规划资源,节约用电,同时帮助电力公司规划电源建设,优化能源结构<sup>[1-3]</sup>。

NILM最早的方法是基于组合优化的解聚技术,采用诸如进化算法、线性 and 非线性整数规划等方法进行非侵入负荷分解<sup>[4-6]</sup>。但是,组合优化方法在任一时间均独立执行功率分解,不考虑负荷随时间的变化。这些算法对噪音非常敏感,只对安装少量电器的用户分解准确。因此,此类方法不适合应用于现实生活场景。

随着研究的深入,机器学习被证明是解决NILM问题的关键技术,例如K-近邻、支持向量机、决策树

等分类器<sup>[7-8]</sup>。文献[9]为了减少模型计算学习的时间,提高分类性能,提出了一种改进的K-最近邻算法,提高了对于不同类别电器之间的辨别能力。但是,机器学习方法适用于浅层网络和小批量数据,随着电器设备数量和类别的增加,这些方法会遇到可扩展性问题,阻碍模型的性能。

2015年开始,深度学习模型被应用到NILM领域中。文献[10]首次基于序列到序列和神经网络来建模,利用滑动窗口解决功率序列数据训练问题,尝试使用递归神经网络<sup>[11]</sup>和去噪自动编码器<sup>[12]</sup>在输入序列和输出序列之间进行映射,取得了先进的成果。此后,很多学者基于序列到序列进行改进<sup>[13-14]</sup>。文献[15]提出了一种基于互感器双向编码器表示和改进目标函数的结构,性能优于其他序列到序列模型。然而,当输入和输出序列的长度变长时,应用序列到序列学习使训练过程难以收敛。针对此难题,文献[16]提出了序列到点模型,在输入序列和输出序列中点之间进行映射,解决了输出信号的每个元素被预测多次,从而平滑边缘的问题。在此基础上,众多研究进行了网络结构的优

化<sup>[17-19]</sup>。文献[20]利用时域卷积网络训练负荷分解模型,并用激活函数 Gelu 代替传统的激活函数 Relu,有效提高了分解精度。但是,序列到点方法的每个正向过程只产生一个输出信号,因此在推断期间引入了太多的计算量。文献[21]权衡了序列到序列和序列到点两种方法的利弊,提出序列到子序列的方法。此外,目前非侵入负荷分解模型均只利用负荷数据的时间序列信息,将NILM问题定义为回归任务。文献[22]为了将时间序列功率信息和开/关状态信息进行结合,基于多任务学习的思想,提出了子任务门控网络(subtask gated networks,SGN),同时进行回归任务和分类任务,有效提高分解效率。但是这项研究中的回归和分类网络均基于序列到序列方法,处理长时间序列数据时模型收敛困难。

针对以上问题,文中提出了基于序列到子序列和SGN的非侵入负荷分解模型,并尝试在SGN的两个分支网络中添加空间注意力和通道注意力模块。本文主要研究内容如下:

(1) 采用序列到子序列方法构建网络模型,实现电源主序列到目标电器子序列中间较短部分的映射,减小模型收敛的困难度和推理周期的计算量。

(2) 基于多任务学习的思想,构建回归子网络和分类子网络,利用目标电器开/关状态分类任务降低功率分解回归任务的误差,提高功率分解精度。

(3) 在回归子网络和分类子网络中添加通道注意力机制和空间注意力机制,混合注意力机制考虑到卷积层输出对各通道的依赖性,选择性地增强信息量最大的特征,减少特征学习过程中其他电器的噪声干扰。

## 1 非侵入负荷分解模型

### 1.1 非侵入负荷分解概念

非侵入负荷分解指在家庭电力入口处安装传感装置采集总负荷数据,然后进行分析,得到各用电设备的用电量以及用电模式。

文中的分解信号为采集到的功率数据。假设  $Y(t)$  为  $t$  时刻某一家庭的主电源读数,  $X_i(t)$  为  $t$  时刻设备  $i$  的电源读数,则可表示如下

$$Y = \sum_{t=1}^T Y(t) + \varepsilon \quad (1)$$

$$Y(t) = \sum_{i=1}^m X_i(t) + \varepsilon_i \quad (2)$$

式中:  $T$  为采集功率数据的时间段;  $m$  为家庭中被观测电器的总个数;  $\varepsilon$  为当平均值为 0、方差为  $\sigma^2$  时的高斯噪声因子,即为家庭中未被观测到的电器设备的干扰读数。非侵入负荷分解的任务则是根

据  $Y(t)$  得到  $X_i(t)$ 。

### 1.2 序列到子序列方法

深度学习在NILM任务中的应用是建立主电源读数和设备读数之间的映射关系。序列到序列方法是将给定窗口长度  $W$  的主电源读数映射到相同长度窗口的设备读数,表述为  $Y_{(t+(W-1))} \rightarrow X_{(t+(W-1))}$ 。序列到点方法是将给定窗口长度  $W$  的主电源读数映射到该窗口中点的设备读数,表述为  $Y_{(t+(W-1))} \rightarrow X_{(t+\lfloor \frac{W}{2} \rfloor)}$ 。序列到子序列方法则是将以上两种方法进行结合,将给定窗口长度  $W$  的主电源读数映射到较小窗口  $W_i$  的设备读数,其中  $W_i$  是  $W$  的中间部分,表述为  $Y_{(t+(W-1))} \rightarrow X_{(\lfloor \frac{W-W_i}{2} \rfloor)(t+\lfloor \frac{W+W_i}{2} \rfloor)}$ ,既避免了

序列到序列方法平滑窗口边缘的缺点,又解决了序列到点方法计算量过多,输入利用率低的问题。另外,为了避免主电源读数窗口边缘丢失上下文信息,文中在输入的窗口两侧均增加长度为  $L$  的时间序列,则模型表述为  $Y_{(t-L)(t+W+L-1)} \rightarrow X_{(\lfloor \frac{W-W_i}{2} \rfloor)(t+\lfloor \frac{W+W_i}{2} \rfloor)}$ 。

### 1.3 通道注意力与空间注意力

将文献[23]提出的卷积块注意模块应用到NILM任务中,可提高模型的特征表达能力。若给定的输入特征图为  $F$ ,卷积块注意模块首先通过式(3)得到维度为 1 的通道注意图  $M_c$ ,然后通过式(4)得到二维空间注意图  $M_s$ ,两者表示如下

$$F' = M_c(F) \otimes F \quad (3)$$

$$F'' = M_s(F) \otimes F' \quad (4)$$

式中:  $\otimes$  为两个特征映射逐元素相乘;  $F'$  为通道注意特征图与输入特征图相乘得到的特征映射;  $F''$  为经过空间注意模块调整得到的最终特征映射。

#### 1.3.1 通道注意力

普通的卷积层没有考虑每个通道之间的依赖程度,每一个卷积层的卷积核可以视为一个特征通道。通道注意力模块首先同时进行最大池化和均值池化,得到平均池特征  $F_{avg}^c$  和最大池特征  $F_{max}^c$ ,然后分别由多层感知器(multi-layer perceptron,MLP)和一个隐藏层组成的共享网络计算两个特征,输出结果直接求和,最终使用 sigmoid 函数获得通道注意特征图  $M_c \in R^{C \times 1 \times 1}$ 。结构图如图 1 所示,其过程表达如下

$$\begin{aligned} M_c(F) &= \sigma(M_{lp}(Pool(F)) + M_{lp}(MaxPool(F))) \\ &= \sigma(W_1(W_0(F_{avg}^c)) + W_1(W_0(F_{max}^c))) \end{aligned} \quad (5)$$

式中:  $\sigma$  为 sigmoid 函数;  $W_0$ 、 $W_1$  为权重参数,  $W_0 \in R^{C/c \times c}$ ,  $W_1 \in R^{c \times c/c}$ ;  $W_{lp}$  为多层感知器模型函数;  $MaxPool$  为最大池化函数。




图1 通道注意力模块

Fig. 1 Channel attention module

### 1.3.2 空间注意力

空间注意力关注“哪里”是重要信息,与通道注意力互补。如公式(6)所示,通道注意模块和初始特征图计算得到的  $F'$  在通道轴上进行平均池和最大池操作,分别得到  $F_{avg}^s \in R^{1 \times H \times W}$  和  $F_{max}^s \in R^{1 \times H \times W}$ , 然后将其连接成一个二维特征图,输入到卷积核为  $7 \times 7$  的隐藏层进行卷积得到与输入特征图维度一致的二维特征映射,最终使用 sigmoid 函数获得空间注意特征图  $M_s \in R^{1 \times H \times W}$ 。空间注意力模块结构图如图2所示,其过程表达如下

$$M_s(F) = \sigma\left(f^{7 \times 7}\left(\text{AvgPool}(F); \text{MaxPool}(F)\right)\right) \quad (6)$$

$$= \sigma\left(f^{7 \times 7}\left(F_{avg}^s, F_{max}^s\right)\right)$$

式中:  $\text{AvgPool}$  为平均池化函数。




图2 空间注意力模块

Fig. 2 Spatial attention module

## 2 基于改进SGN的非侵入负荷分解模型

### 2.1 模型整体架构

文中将电器开/关状态作为门控机制,为其添加门控损失,使得模型可以直接从门控分类子网进行学习,并且与主回归任务结合共同形成模型的最终输出,分解模型如图3所示。




图3 基于序列到子序列和SGN的整体结构图

Fig. 3 Schematic based on sequence-to-subsequence and SGN

将上文定义的主电源功率序列  $Y_{(t-L):(t+W+L-1)}$  分别输入到两个分支网络,主回归任务输出窗口长度为  $W$  的设备功率序列  $X_{\left\lfloor \frac{W-W_i}{2} \right\rfloor (t) : \left\lceil \frac{W+W_i}{2} \right\rceil (t)}$ , 将其映射关系

简化为  $Y \rightarrow f_{power}^i(Y)$ ; 分类子任务输出设备相应窗口的开/关状态概率值,将其映射关系定义为  $Y \rightarrow f_{on}^i(Y)$ 。假设  $O^i = (O_1^i, O_2^i, \dots, O_w^i)$  为第  $i$  个设备的开/关状态序列,  $O_t^i \in \{0, 1\}$  为  $t$  时刻设备  $i$  的开/关状态, 0 代表设备关闭, 1 代表开启。最终模型的输出定义为  $f_{output}^i(Y)$ , 计算方式如下

$$f_{output}^i(Y) = f_{power}^i(Y) \otimes H(f_{on}^i(Y)) \quad (7)$$

式中:  $\otimes$  为两个输出结果逐元素相乘,不同于文献[22]的计算方式,文中不再是将回归网络输出的功率值直接乘以电器开/关的概率值,而是乘以 0 或者 1, 函数  $H$  直接将小于 0.5 的概率值转换为 0, 反之, 转换为 1。

在整个模型架构中,我们分别利用以下损失函数进行优化

$$L_{output}^i = \frac{1}{W} \sum_{t=1}^W \left( X_t^i - f_{power}^i(Y) \otimes H(f_{on}^i(Y)) \right) \quad (8)$$

$$L_{power}^i = \frac{1}{W} \sum_{t=1}^W \left( X_t^i - f_{power}^i(Y) \right)^2 \quad (9)$$

$$L_{on}^i = \frac{1}{W} \sum_{t=1}^W \left( X_t^i - H(f_{on}^i(Y)) \right)^2 \quad (10)$$

### 2.2 子网络架构

结合通道注意力机制和空间注意力机制的子网络架构如图4所示。首先通过 5 层基本卷积学习特征; 然后经过通道注意力和空间注意力模块细化特征; 最后全连接层实现线性映射, 得到输出结果。




图4 分支网络模型

Fig. 4 Branch network model

## 3 实验分析与结果

### 3.1 性能指标

两个性能指标用于评估提出的模型,分别为平均绝对误差(mean absolute error, MAE)和均方根误差(root-mean-square error, RMSE)。根据 1.1 节的定义,  $X_t$  为  $t$  时刻设备的真实读数,  $\tilde{X}_t$  为  $t$  时刻本文

模型的预测输出读数,MAE显示每个时刻真实值和预测值的平均差,表示为 $\frac{1}{T} \sum_{i=1}^T |\hat{X}_i - X_i|$ ,RMSE显示每个时刻预测值与真实值偏差的平方与总观测时间 $T$ 比值的平方根,表示为 $\frac{1}{T} \sqrt{\sum_{i=1}^T (\hat{X}_i - X_i)^2}$ 。

### 3.2 数据分析与处理

#### 3.2.1 数据集及电器分析

本文使用文献[24]公布的UK-dale数据集进行实验。数据采样时间周期为2012年11月到2015年1月,每个家庭的数据包括一个主电源功率读数和其对应的每个电器的单独功率读数。

文献[25]根据工作模式将电器分为4类,分别为开/关两状态电器、多状态电器、连续变化型电器和持续工作型电器。开/关两状态电器工作模式单一,运行期间功率恒定;多状态电器的多种工作模式是相对固定的,每个工作模式每次运行时功率值较稳定,而且一种模式切换到另一种模式时,功率的变化过程也较稳定。文中主要以这两种电器类型为研究对象,通过对5个家庭的电器种类进行统计,发现家庭1、2、5均包含5种电器,文中采用家庭1、2进行实验。

#### 3.2.2 数据处理

在数据采集过程中,由于设备原因,很多采样点缺失数据,本文利用NILMTK<sup>[26-27]</sup>工具包中的预处理方式进行了数据分割,当任意两个连续数据样本间的时间间隔大于3 min,则将其删除。另外,我们对数据进行了归一化和标准化处理。

### 3.3 结果分析与可视化

文中选取家庭1中2013年5—12月的数据和2014年1—8月的数据作为训练集,其中20%划分为验证集,家庭1中2014年8—12月的数据作为测试集,故测试集与训练集相互独立,无重叠部分。在实验过程中,聚合功率窗口长度为200,对应1 200 s的连续样本;目标电器窗口长度为32,对应192 s的连续样本;聚合功率窗口两侧增加的额外时间序列长度为32,对应192 s的连续样本。

为了验证文中序列到子序列模式相较于序列到序列和序列到点收敛速度快、模型推理计算量小的优势,我们首先将SGN网络分别构建为以上3种模式,以洗碗机的训练结果为例,迭代次数对比如图5所示,模型训练结果如表1所示。

由表1可知,在序列到子序列模式下,参数量和训练时间两个指标优于序列到序列,计算量优于序列到点。由图5可知,序列到点和序列到子序列的第1次和第2次训练大幅度降低了loss值,在第13次训练时达到了基本稳定;但是序列到序列模式在第8次训练

才达到前两种方法第2次的训练效果,并且最终达到模型性能稳定时,训练次数为21,由此看出序列到子序列模式改进了序列到序列方式模型收敛速度慢的问题,并且大幅减小了序列到点的计算量。

表1 洗碗机3种构建模式性能对比

Table 1 Comparison of metrics of three construction modes of dishwasher

模型	耗时/min	参数量	计算量
SGN_序列到序列	630	20 966 848	179 248
SGN_序列到点	309	13 288 498	35 442 048
SGN_序列到子序列	489	20 622 448	1 109 548

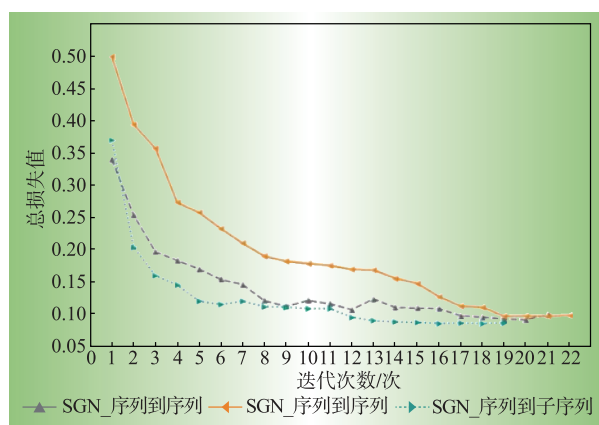


图5 不同训练次数的损失值

Fig. 5 Loss values of different epochs

为了验证文中添加的通道注意力和空间注意力的有效性,以冰箱为例,图6显示了训练过程中,模型有/无注意力模块的迭代过程中损失值的变化。结果显示,两个注意力模块对于回归子网和分类子网的性能提升均有帮助,尤其是很大程度上降低了分类网络的损失值,更大程度上发挥了分类门控子网对于非侵入负荷分解任务的修正作用。




图6 有无注意力模块的损失值的对比

Fig. 6 Comparison of loss value with and without attention module

为了验证模型的分解性能,我们在相同的实验环境下,将提出的模型与其他模型进行对比,结果如表2所示。结果显示,文献[22]提出的SGN模型相较于DAE和序列到点模型,在运行时间长的电器上表现出优势,但是在水壶和微波炉这种运行时间短的电器上性能反而降低,这是因为这两种电器运行时功率变化快,SGN模型难以学习到特征。相较于SGN模型,文中的模型在大部分电器上的性能表现优异,水壶和微波炉的效果最为明显,水壶的平均绝对误差降低了87%,均方根误差降低了67%,微波炉的平均绝对误差降低了62%,均方根误差基本持平,说明文中添加的混合注意力机制改进了短时间运行电器信息难以提取的问题并且增强了长时间运行电器的特征提取能力,减少了噪声的影响。相较于文献[28]提出的模型,本文模型在开/关状态电器上分解效果具有优势,在多状态长时间运行的电器上分解精度略差,说明本文模型在提取多状态变化特征时具有困难,但是文献[28]提出的多头概率稀疏自注意机制扩展了模型集中于不同位置的能力,能够更好地拟合多种特征。

图7给出了5种电器局部分解效果对比实验结果,由图7可知文中的模型有效提高了5种电器的分解精度。对于小功率电器冰箱而言,文中模型几乎拟合了真实分解值,但是对比模型存在较大波动;对于水壶和微波炉这两种运行时间短、功率变化为瞬时状态的电器,文中模型可以精准地捕获到特征变化,但是SGN模型很难学习到突变的特征,分解值几乎为一条平滑的直线,文献[28]提出的模型分解精度基本与本文持平,但是在功率突变时,分解值与真实值差距较大;对于运行时间长的大功率电器,文中提出的模型在电器开启时功率分解精度略胜于SGN模型,分解值更加接近于真实值,功率变化情况捕获更加准确,但是与文献[28]相比,本文模型在多状态功率峰值分解精度不佳,与真实值有一定差距。

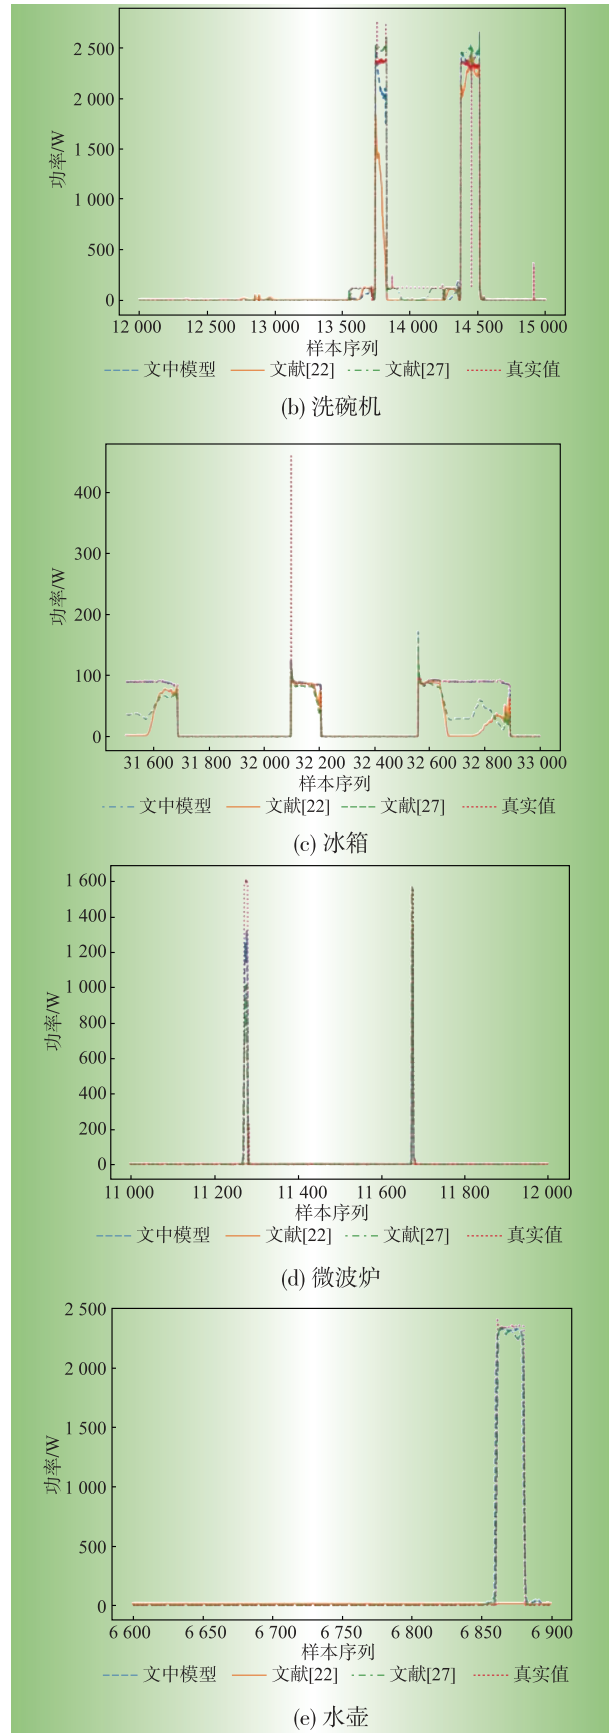



图7 电器分解效果对比

Fig. 7 Comparison of decomposition effects of electrical appliances

表2 模型分解结果对比

Table 2 Comparison of model disaggregation results

评价指标	电器	DAE	序列到点	SGN <sup>[22]</sup>	文献[27]	本文模型
MAE	水壶	5.183 376	3.643 462	23.814 602	3.538 123	3.004 093
	冰箱	25.433 741	24.838 352	17.606 646	15.096 428	12.557 886
	洗衣机	11.895 802	7.945 657	6.019 336	4.237 641	5.089 711
	洗碗机	13.106 861	6.902 247	6.490 891	5.001 378	5.272 381
	微波炉	4.978 332	4.549 595	8.166 995	3.985 431	3.126 100
RMSE	水壶	70.772 175	52.678 570	177.162 879	59.869 036	57.564 016
	冰箱	43.435 236	44.498 557	40.474 292	32.794 087	30.775 085
	洗衣机	73.465 161	44.416 028	43.303 375	37.163 581	39.566 849
	洗碗机	100.088 403	41.944 522	55.366 594	38.123 925	37.989 423
	微波炉	55.153 222	50.538 649	72.166 315	52.132 763	49.038 860

## 4 结束语

本文提出了基于序列到子序列和SGN的非侵入负荷分解模型,以序列到子序列的模式构建网络,解决了序列到序列中模型收敛困难以及序列到点计算量大的问题,在两者之间进行了平衡;且将负荷分解任务同时定义为回归任务和分类任务,构建了多任务框架,在每个子任务网络中添加了通道注意力机制和空间注意力机制,有效提高了模型提取特征的能力。实验结果表明,本文提出的模型不仅减小了模型收敛的困难度和推理周期的计算量,而且减小了平均绝对误差和均方根误差,提高了分解精度,未来可以进一步调整网络结构,增强网络的泛化性,并将网络部署到实际场景中,提高其实用性。D

## 参考文献:

- [1] LANGEVIN A, CARBONNEAU M A, CHERIET M, et al. Energy disaggregation using variational autoencoders [J]. Energy and Buildings, 2022, (254): 111 623.
- [2] 白新雷,张凯,冯剑,等. 面向用电负荷精细化调控的需求侧管理平台设计[J]. 电力需求侧管理, 2021, 23(5): 86-90.  
BAI Xinlei, ZHANG Kai, FENG Jian, et al. Design of demand-side management platform for fine-tuning electrical load control [J]. Power Demand Side Management, 2021, 23(5): 86-90.
- [3] 严永辉,李新家,王淑云,等. 基于云端协同的家用电器负荷辨识能力提升技术研究[J]. 电力需求侧管理, 2021, 23(3): 58-63.  
YAN Yonghui, LI Xinjia, WANG Shuyun, et al. Research

on technology of improving the identification ability of household electrical appliances based on cloud collaboration [J]. Power Demand Side Management, 2021, 23(3): 58-63.

- [4] 孙毅,李昊洋,刘耀先,等. 基于改进隐马尔科夫模型的非侵入式家居负荷识别[J]. 电力建设, 2020, 41(4): 73-80.  
SUN Yi, LI Haoyang, LIU Yaoxian, et al. Non-intrusive home-load identification based on improved hidden markov model [J]. Electric Power Construction, 2020, 41(4): 73-80.
- [5] BALLETTI M, PICCIALI V, SUDOSO A M. Mixed-integer nonlinear programming for state-based non-intrusive load monitoring [J]. ArXiv Preprint ArXiv: 2106.09158, 2021.
- [6] LI P, DU Q, FAN Y, et al. Applications of feature weighted fuzzy c-means clustering and genetic algorithm optimization for load identification in nilm systems [C]//2020 International Conference on Wavelet Analysis and Pattern Recognition (ICWAPR), IEEE, 2020: 72-77.
- [7] 牟魁翌,杨洪耕. 基于PLA-GDTW支持向量机的非侵入式负荷监测方法[J]. 电网技术, 2019, 43(11): 4 185-4 193.  
MOU Kuiyi, YANG Honggeng. Non-intrusive load identification method based on PLA-GDTW support vector machine [J]. Power System Technology, 2019, 43(11): 4 185-4 193.
- [8] 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.
- [9] HIMEUR Y, ALSALEMI A, BENSAAALI F, et al. Smart non-intrusive appliance identification using a novel local

- power histogramming descriptor with an improved k-nearest neighbors classifier [J]. *Sustainable Cities and Society*, 2021(67):102-764.
- [10] KELLY J, KNOTTENBELT W. Neural nilm: deep neural networks applied to energy disaggregation [C]//Proceedings of the 2nd ACM International Conference on Embedded Systems for Energy-efficient Built Environments, 2015:55-64.
- [11] CHO K, VAN MERRIËNBOER B, GULCEHRE C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation [J]. *ArXiv Preprint ArXiv*, 2014(1406):1078.
- [12] VINCENT P, LAROCHELLE H, BENGIO Y, et al. Extracting and composing robust features with denoising autoencoders [C]//Proceedings of the 25th International Conference on Machine Learning, 2008:1096-1103.
- [13] 王轲, 钟海旺, 余南鹏, 等. 基于 seq2seq 和 Attention 机制的居民用户非侵入式负荷分解 [J]. *中国电机工程学报*, 2019, 39(1):75-83, 322.  
WANG Ke, ZHONG Haiwang, YU Nanpeng, et al. Non-intrusive load monitoring based on sequence-to-sequence model with attention mechanism [J]. *Proceedings of the CSEE*, 2019, 39(1):75-83, 322.
- [14] 任文龙, 许刚. 基于深度序列翻译模型的非侵入式负荷分解方法 [J]. *电网技术*, 2020, 44(1):27-37.  
REN Wenlong, XU Gang. Non-intrusive load decomposition method based on deep sequence translation model [J]. *Power System Technology*, 2020, 44(1):27-37.
- [15] YUE Z, WITZIG C R, JORDE D, et al. Bert4nilm: a bidirectional transformer model for non-intrusive load monitoring [C]//Proceedings of the 5th International Workshop on Non-Intrusive Load Monitoring, 2020:89-93.
- [16] ZHANG C, ZHONG M, WANG Z, et al. Sequence-to-point learning with neural networks for non-intrusive load monitoring [C]//Proceedings of the AAAI Conference on Artificial Intelligence. 2018, 32(1):110-122.
- [17] LIN N, ZHOU B, YANG G, et al. Multi-head attention networks for nonintrusive load monitoring [C]//2020 IEEE International Conference on Signal Processing, Communications and Computing (ICSPCC), IEEE, 2020:1-5.
- [18] YANG W, PANG C, HUANG J, et al. Sequence-to-point learning based on temporal convolutional networks for nonintrusive load monitoring [J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70:1-10.
- [19] 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):4329-4337.  
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):4329-4337.
- [20] KASELIMI M, DOULAMIS N, VOULODIMOS A, et al. Context aware energy disaggregation using adaptive bidirectional LSTM models [J]. *IEEE Transactions on Smart Grid*, 2020, 11(4):3054-3067.
- [21] PAN Y, LIU K, SHEN Z, et al. Sequence-to-subsequence learning with conditional gan for power disaggregation [C]//ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), IEEE, 2020:3202-3206.
- [22] SHIN C, JOO S, YIM J, et al. Subtask gated networks for non-intrusive load monitoring [C]//Proceedings of the AAAI Conference on Artificial Intelligence, 2019, 33(1):1150-1157.
- [23] WOO S, PARK J, LEE J Y, et al. Cbam: convolutional block attention module [C]//Proceedings of the European Conference on Computer Vision (ECCV), 2018:3-19.
- [24] KELLY J, KNOTTENBELT W. The UK-DALE dataset, domestic appliance-level electricity demand and whole-house demand from five UK homes [J]. *Scientific Data*, 2015, 2(1):1-14.
- [25] HART G W. Prototype nonintrusive appliance load monitor: progress report 2 [M]. MIT Energy Laboratory, 1985.
- [26] BATRA N, KELLY J, PARSON O, et al. NILMTK: an open source toolkit for non-intrusive load monitoring [C]//Proceedings of the 5th international conference on Future energy systems, 2014:265-276.
- [27] 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.  
XIE Yang, MEI Fei, ZHENG Jianyong, et al. Non-intrusive Load Monitoring Method Based on V-I Trajectory Color Coding [J]. *Automation of Electric Power Systems*, 2022, 46(4):93-102.
- [28] 陈俊, 彭勇刚, 凌家源, 等. 基于概率稀疏自注意力模型的非侵入式负荷分解 [J/OL]. (2022-06-01)[2022-10-08]. *电网技术*, 2022, 46(15):1-11.  
CHEN Jun, PENG Yonggang, LING Jiayuan, et al. Non-intrusive load disaggregation based on probabilistic sparse self-attention model [J/OL]. (2022-06-01)[2022-10-08]. *Power System Technology*, 2022, 46(15):1-11.

#### 作者简介:

郭艳霞(1997),女,河北张家口人,硕士,研究方向为非侵入负荷监测、能源需求响应资源规划等;

徐正一(1998),男,河北石家庄人,硕士研究生,研究方向为NLP领域深度学习算法、电力大数据挖掘与分析等;

琚贇(1982),男,江西黎川人,博士,高级工程师,研究方向为电力市场、电力系统规划与运行等。

(责任编辑 水 鹤)