

Research on Non-Intrusive Load Monitoring Method Based on Multi-Layer and Multi-Kernel Convolution Neural Network*

WANG Tao¹, LIANG Ruiyu^{2*}, HUANG Hu¹, DING Chao¹

(1.School of Electrical Engineering, Nanjing Institute of Technology, Nanjing Jiangsu 211100, China;

2.School of Information and Communication, Nanjing Institute of Technology, Nanjing Jiangsu 211100, China) 5.56mm]

Abstract: Only by measuring the total load voltage, current, power and other signals carrying power information, non-invasive load monitoring can achieve load monitoring without additional metering devices and line transformation, so it has been widely studied. Aiming at the low accuracy of the traditional deep neural network decomposition model, a decomposition model based on multi-layer and multi-core convolution deep neural networks is proposed. In order to reflect the characteristics of different devices, different sequence lengths are used in data segmentation. Then, the model first transforms the input power time series into high-dimensional vectors by high-dimensional mapping and then designs the multi-layer and multi-core convolution deep neural networks to extract the features of the generated vectors. Finally, the load decomposition model is generated after repeated iterative learning. Compared with other deep learning methods for non-intrusive load decomposition, the model improves the accuracy of load identification obviously, and the recognition accuracy on REDD data set reaches 99.41%.

Key words: non-intrusive load monitoring; deep learning; multi-kernel convolutional network; power internet of things
EEACC: 7210 doi: 10.3969/j.issn.1005-9490.2021.06.024

基于多层多核卷积神经网络的非侵入式 负荷监测方法研究*

汪 涛¹, 梁瑞宇^{2*}, 黄 虎¹, 丁 超¹

(1.南京工程学院电力工程学院, 江苏 南京 211100; 2.南京工程学院信息与通信工程学院, 江苏 南京 211100)

摘 要: 非侵入式负荷监测仅依靠测量得到的总负荷的电压、电流与功率等承载电力信息的信号就实现负荷监测, 无需额外的计量装置和线路改造, 因此得到广泛研究。针对传统深度神经网络分解模型准确度仍不能满足实际需求的现状, 提出了一种基于多层多核卷积深度神经网络分解模型。为体现不同设备的特性, 模型在数据分割时采用不同的序列长度。然后, 模型将分割后的数据先通过高维映射, 将输入的功率时间序列映射到高维向量, 再利用多层卷积法与多核卷积法共同构建出的深度神经网络对生成的信息向量进行特征提取, 经多次迭代学习生成负荷分解模型。与多种用于非侵入式负荷分解的深度学习学习方法相比, 本模型对负荷识别准确率提升效果显著, 在 REDD 数据集上的识别准确率达到 99.41%。

关键词: 非侵入式负荷监测; 深度学习; 多核卷积网络; 电力物联网

中图分类号: TP306

文献标识码: A

文章编号: 1005-9490(2021)06-1429-07

非侵入式负荷监测 (Non-Intrusive Load Monitoring, NILM) 是一种利用大数据分析对电力系统负荷进行检测与分解的技术^[1], 对电力需求侧管理的决策制度以及电网和电力用户互动体系的构建有着重要的意义。相比于侵入式负荷监测, NILM 需要安装的传感设备数量较少, 是一种快捷、经济的负荷监测方法^[2-3]。近年来, 随着大数据分析、智能电网、智能电表^[4]和智能家居等技术的不断成熟与推广,

越来越多的学者开始专注于 NILM 研究。

20 世纪 80 年代, 英国学者 Hart^[5] 提出了非侵入式负荷监测的概念, 同时构建了实现 NILM 的框架结构。目前, 非侵入式负荷监测可分为以高频采样和以低频采样数据为基础的两种研究方法。以高频采样数据为基础的 NILM, 通过获取负荷开断时刻的暂态特征进行负荷识别与分解。文献[6]提出了一种粒子群聚类算法, 将电压有效值、电流有效值和

项目来源: 江苏省研究生实践创新计划项目 (SJCX21_0948)

收稿日期: 2020-12-31 修改日期: 2021-02-15

3 次谐波作为负荷特征,实验证明了粒子群优化能够提高算法收敛到全局最优的速度。文献[7]通过提取电流图片特征辨别负荷类型。文献[8]提出一种强化谐波幅值差异的算法,对负荷谐波信息进行加权处理,模型对相似负荷电器的区别能力得到提升。以低频采样数据为基础的 NILM,通过获取负荷的稳态特征,如稳态时的电压、电流、有功功率进行负荷识别与分解。文献[9-10]采用深度字典学习实现负荷分解。文献[9]提出深度稀疏编码法为各项设备学习多层字典,模型在学习深层字典后分解性能提升,但随着字典的深入,模型参数过拟合现象也越发严重。文献[10]提出基于多标签分类的分解方法,将不同设备视为不同的类,最终把负荷分解问题转化为多元回归问题。文献[11]不同于传统的因子隐马尔可夫模型(Factorial Hidden Markov Model, FHMM 模型),提出一种结合加法因子隐马尔可夫模型和减法因子隐马尔可夫模型两者优点的可加性概率模型,并实验证明了该想法的有效性。

近年,鉴于深度学习的方法在语音识别、计算机视觉等多项领域获得突破进展,已经有一些学者使用深度学习^[1]的方法实现非侵入式负荷分解。2015 年,英国学者 Kelly^[12]第一次实现基于深度学习的非侵入式负荷分解,并采用三种模型进行验证,对比于传统隐马尔可夫模型和组合优化模型,算法的负荷分解准确度得到了显著提升。文献[13]提出了一种通用的深度学习分解模型,并提供相应的固定模型架构及超参数,模型能够适应各种类型的负荷,但分解性能相对较低。文献[14]提出了一种变分自编码的卷积神经网络模型,卷积神经网络对特征的提取能力强,将卷积网络与自编码相结合,能够有效地实现负荷分解。文献[15]和文献[16]对常规的长短时记忆网络模型进行了优化,所提的贝叶斯优化双向长短时记忆(long short term memory, LSTM)模型和正则化 LSTM 模型可以解决由设备数量增加而引起的维数过大和参数过拟合问题。文献[17]针对序列到序列(sequence-to-sequence, seq2seq)模型中输入序列过长导致的模型运算能力下降问题,提出一种注意机制,使模型在解码过程中拥有了侧重点,优化了序列到序列模型的信息利用能力。文献[18]提出一种可变步长的去噪自编码器模型,在数据有噪声情形下分解性能较好。文献[19]提出一种序列到点(sequence-to-point, seq2point)模型,相比于序列到序列模型,负荷分解的绝对误差和与平均绝对误差都有所减小。文献[20]论述并证明了基于 V-I 轨迹特征进行负荷分解时所提模型具

备的可迁移性。文献[21]提出设备迁移学习模型和跨域迁移学习模型,证明了 seq2point 模型是可以迁移的。文献[22]通过对比实验,证明了长短时记忆算法在 NILM 领域的优越性。文献[23]提出一种基于时间卷积网络的半监督多标签深度学习框架,结合有标签数据和无标签数据实现了特定电器的开关状态监测。虽然上述模型都成功运用了深度学习的方法,但仍然未能提出关于深层次特征信息提取的优化方法,模型特征提取层次仅有一至两层,所以这些模型对于负荷监测的识别准确率还有待提高。

为此,本文提出一种基于多层多核卷积神经网络的负荷监测模型,利用 REDD 公开数据集完成了模型的训练与测试,并与多层单核网络模型及目前认可度较高的 CNN-LSTM 模型^[12]对比,以验证本文模型对负荷识别准确度的提升效果。

1 模型构成

1.1 模型流程

本文提出的 NILM 模型流程如图 1 所示。

模型首先对低频采样数据进行分段,并将输入的功率序列通过高维映射对应至高维向量序列,最后通过本文所提神经网络进行训练和分解。




图 1 模型流程图

1.2 数据预处理

1.2.1 数据切割

由于用于 NILM 训练的样本数据数量级可以达到 10^4 甚至 10^6 ,因此本文首先对采样数据进行数据切割,使输入序列的长度为一固定值。

由于不同种类的电器能够代表其电气特征的数据长度不同,故对不同电器需要设定不同的序列长度。假设功率数据中含有 M 种不同的电器 $\{A_1, A_2,$

$\dots, A_M\}$, 对应网络模型输入序列长度分别设置为 $\{N_1, N_2, \dots, N_M\}$, 再由设定的序列长度对功率数据进行数据切割, 使其分为若干数据段。

1.2.2 高维映射

高维映射包含两个步骤, 第一步是输入总负荷有功功率序列 $\{P_1, P_2, \dots, P_{N_i}\}$, 进行整数化处理得到 $\{P_1, P_2, \dots, P_{N_i}\}$ 。第2步为将整数化处理后的有功功率序列中每个值 P_i , 通过高维映射矩阵 $E = [v_s * e_s]$ 映射到高维向量 $E[P_i]$, 得到映射后的序列 $\{E[P_1], E[P_2], \dots, E[P_{N_i}]\}$, 将 $E[P_i]$ 作为 $A[1: N_i]$ 生成输入矩阵 A 。高维映射矩阵 E 中的第一维度 v_s 为功率大小, 第二维度 e_s 为设备序列长度。将整数有功功率映射到高维向量, 实现了输入序列的抽象, 同时也确定了高维向量与功率的对应关系, 其作为本文深度神经网络的输入, 有利于后续编码器对时序信息的提取和负荷的分解。

1.3 网络构成

1.3.1 卷积神经网络

卷积神经网络中包含卷积层、池化层、全连接层等基本功能层^[24]。各个层具有独立的神经元, 不同层神经元间相互连接, 同层神经元间无连接。卷积层计算公式为

$$X_j^l = f(X_j^{l-1} * K_j^l + b_j^l) \quad (1)$$

式中: X_j^l 表示第 l 层的第 j 个滤波器特征; $X_j^{l-1} * K_j^l$ 表示第 $l-1$ 层第 j 个滤波器特征和第 l 层卷积核的卷积核函数; b_j^l 为第 l 层的第 j 个偏置参数。 f 函数为激活函数; 一般来说卷积层还有 2-D 卷积层、3-D 卷积层、转置卷积层和分组卷积层等。池化层计算公式为:

$$L_j^i = f(a_j^i \text{down}(L_j^{i-1}) + b_j^i) \quad (2)$$

式中: a_j^i 和 b_j^i 分别表示网络层之间的权重和偏置参数; $\text{down}(\cdot)$ 为池化函数; $f(\cdot)$ 是激活函数。池化层用来降低分辨率, 常用的池化层有平均池化层、最大池化层以及全局平均池化层。本文选用 Relu 函数作为激活函数, Relu 函数对输入的每个元素执行阈值运算, 任何小于零的值都设置为零。经过卷积层和池化层的计算后原始数据特征便映射到了隐含特征空间, 通过全连接层标记这些特征空间便能提取原数据特征, 然后利用 softmax 层概率分类。后继的网络层还有批量归一化层、dropout 层(脱落层)等。批量归一化层对网络中的激活值和梯度传播进行归一化, 使网络训练成为更简单的优化问题, dropout 层则可以防止过度拟合。模型得到结果后会通过反向传播方式调整模型网络参数。

1.3.2 LSTM 神经网络

卷积神经网络 LSTM 是一种特殊的循环神经网络(RNN), 解决了长依赖性问题的, 在处理时间序列方面具有良好的性能。LSTM 神经网络由序列输入层、LSTM 层、全连接层、dropout 层(值为 0.1)、softmax 层以及分类层组成。使用具有动量的梯度随机下降优化器训练网络, 网络训练参数设置如下: 动量大小为 0.97, L2 正则化(L2 Regularization)因子为 0.000 5, 梯度阈值为 1, 最大迭代数 300, 小批量训练大小为 500, 初始学习率 0.01, 每过 50 代学习率在原有基础上乘 0.2。实验测试发现, 增加 LSTM 层层数会导致辨识效果变差, 为此不再增加 LSTM 神经网络的层数。

1.3.3 多层多核卷积神经网络

由多个卷积核同时卷积进行特征提取的方法称为多核卷积特征提取法。通常情况下, 神经网络使用一个卷积核对负荷特征进行提取, 但一个卷积核只能够提取一种特征, 特征提取并不充分, 因此本文添加多个卷积核, 同时学习功率负荷的多种特征, 目的是提高网络对功率负荷的分辨能力, 进一步达到提高负荷分解准确率的目标。经过之前的高维映射得到输入矩阵 A , 由于每一行的映射向量 $E[P_i]$ 表示一个与其对应的功率, 为了提取有利于功率序列分类的特征, 应当从映射向量的级别进行特征提取, 才能保证功率特征的完整性, 也就是说卷积核的宽度 w 需要完全覆盖映射向量。当卷积核宽度等于映射向量维度时, 卷积核只在竖直方向做卷积, 卷积核的高度表示同时提取几个功率序列的特征。假定输入矩阵 A 的宽度为 w , 高度为 N_i ; 卷积核的宽度也为 w , 高度为 h , 则卷积过程可表示为:

$$O_i = (w * h) * A[i: i-h+1], \quad i = 1, 2, \dots, N_i - h + 1 \quad (3)$$

一个卷积核提取的特征数量为 $N_i - h + 1$, 而不同高度的卷积核提取到的特征大小也不同, 因此本文选择 Max pooling 进行池化操作, 对卷积后的特征映射进行降维, 使其维度统一。通过 Max pooling 提取特征中的最大值得到特征中最重要的部分, 再将负荷特征最大值拼接输入到 softmax 层。

同时, 本文在利用多核卷积网络实现负荷分解的基础上, 加深了网络层数, 使其具有更强特征提取能力, 识别结果更加精确。一维深层神经网络的输入是总有功功率序列转化的 4-D 矩阵。总有功功率序列为 $1 \times n$ 行向量, 将其重构成 $1 \times 1 \times 1 \times n$ 的矩阵, 其中前两维表示 1×1 像素, 第 3 维 1 表示灰度颜色通道, 第 4 维 n 表示序列长度。深层卷积网络由输

入层、A 类层、B 类层、全连接层、softmax 层和分类层组成,共 47 层。A 类层一共 10 组 40 层,每组由 2-D 卷积层、批量归一化、Relu 函数层以及最大池化层构成,每层 2-D 卷积层滤波器数量分别为 8、16、32、64、128、256、512、1 024、2 048、4 096,大小均为 1×1。B 类层由 2-D 卷积层(过滤器数量为 8 192,大小为 1×1)、批量归一化层和 Relu 函数层组成。为了使该模型辨识效果更好,在训练模型时加入了更多的网络参数,为防止模型过度拟合,加入了 L2 正则化因子,其值为 0.000 5,使用具有动量的梯度随机下降优化器训练网络,动量大小为 0.97,梯度阈值为 0.5,最大迭代数为 300,在每一代训练时增加数据混淆,初始学习率为 0.01。为了效果更佳设定学习率梯度下降,每过 50 代学习率在原有基础上乘 0.2。

1.3.4 模型结构

本文模型采用卷积神经网络(convolutional neural networks, CNN)作为网络基础层,设计并实现了多层多核网络结构,对照文献(CNN-LSTM)模型构成如表 1 所示,多层单核(CNN-1d-2)模型构成如表 2 所示,多层多核(CNN-multi-kernel)模型构成如表 3 所示。

表 1 CNN-LSTM 模型构成

Layer(type)	Output Shape	Param
InputLayer	(None, 600, 1)	0
Conv1d	(None, 600, 20)	120
Conv1d	(None, 600, 10)	2 010
Lstm	(None, 600, 20)	2 480
Lstm	(None, 600, 1)	88
Flatten	(None, 600)	0

表 2 CNN-1d-2 模型构成

Layer(type)	Output Shape	Param
InputLayer	(None, 600, 1)	0
Conv1d	(None, 591, 30)	330
MaxPooling	(None, 295, 30)	0
Conv1d	(None, 288, 30)	7 230
MaxPooling	(None, 144, 30)	0
Conv1d	(None, 139, 30)	7 240
MaxPooling	(None, 69, 30)	0
Conv1d	(None, 65, 30)	10 050
MaxPooling	(None, 32, 30)	0
Conv1d	(None, 28, 30)	12 500
MaxPooling	(None, 14, 30)	0
Flatten	(None, 600)	0
Dense	(None, 1024)	717 824
Dense	(None, 600)	615 000

三种网络结构中对照文献(CNN-LSTM)采用两层卷积层两层 LSTM 进行编码解码,多层单核(CNN-1d-2)和多层多核(CNN-multi-kernel)模型均采用 CNN 和最大池化作为基础层,多层单核模型会在每层卷积层之后接池化层,而多层多核模型采用三个卷积核同时进行卷积,之后再接 Max Pooling 进行池化操作。

表 3 CNN-multi-kernel 模型构成

Layer(type)	Output Shape	Param
InputLayer	(None, 600, 1)	0
Conv1d	(None, 598, 20)	80
Conv1d	(None, 596, 20)	120
Conv1d	(None, 591, 30)	220
MaxPooling	(None, 299, 20)	0
MaxPooling	(None, 298, 20)	0
MaxPooling	(None, 295, 30)	0
Conv1d	(None, 297, 30)	1 830
Conv1d	(None, 294, 30)	3 030
Conv1d	(None, 286, 30)	6 030
MaxPooling	(None, 148, 30)	0
MaxPooling	(None, 147, 30)	0
MaxPooling	(None, 143, 30)	0
Conv1d	(None, 146, 40)	3 640
Conv1d	(None, 143, 40)	6 040
Conv1d	(None, 134, 40)	12 040
MaxPooling	(None, 73, 40)	0
MaxPooling	(None, 71, 40)	0
MaxPooling	(None, 67, 40)	0
Conv1d	(None, 71, 50)	12 500
Conv1d	(None, 67, 50)	10 050
Conv1d	(None, 58, 50)	20 050
MaxPooling	(None, 35, 50)	0
MaxPooling	(None, 33, 50)	0
MaxPooling	(None, 29, 50)	0
Flatten	(None, 1750)	0
Flatten	(None, 1650)	0
Flatten	(None, 1450)	0
Concatenate	(None, 4850)	0
Dense	(None, 1200)	5 821 200
Dense	(None, 600)	720 600

2 实验分析

2.1 实验软件平台

本文实验软件平台为 Windows10(64 位)操作系统,Python3.6.8、TensorFlow2.0.0 机器学习平台。编译 IDE 为 PyCharm,数据处理使用 NILMTK 开源工具包。

2.2 数据集

为验证本文所提模型的有效性和准确性,选取 REDD^[25]数据集进行实验。REDD 数据集包含 6 个美国家庭的用电数据。

数据集包含两种家庭用电数据。一种是低频功率数据,包括两处总线路和各个子设备的有功功率数据;另一种是总线路的高频电流和电压的波形数据。本文所提模型使用低频功率数据对网络进行学习。模型将每个家庭用电数据的前 70%用于深度网络的训练,后 30%作为测试数据对模型性能进行测试,数据集训练过程如图 2 所示。




图 2 数据集训练过程框图

2.3 序列长度及激活阈值设定

为了得到用于负荷分解的功率序列,首先要对数据集内各电器序列进行激活提取。本文为实验用到的 5 种电器设定了具体的序列长度及激活阈值,如表 4 所示。

表 4 序列长度及激活阈值

模型	序列长度/点	最小阈值/W	最大阈值/W
冰箱	400	20	300
洗碗机	1 000	20	2 500
水壶	250	20	2 000
微波炉	50	20	1 300
洗衣机	1 200	20	500

2.4 评价指标

为全面评价模型性能,本文选用准确率(precision, PRE)、平均绝对值误差(mean absolute error, MAE)、绝对误差和(signal aggregate error, SAE)和 R^2 决定系数四项指标作为评价标准,具体公式如下:

(1) 准确率 PRE:

PRE=TP / (TP+FP) (4)

式中:TP 为模型判定结果与实际负荷都为运行状态的序列数量;FP 为模型判定结果为非运行状态但实际负荷为运行状态的序列数量。

(2) 平均绝对值误差 MAE:

MAE(y,ŷ)=1 / n_samples * Σ |y_i-ŷ_i| (5)

(3) 绝对误差和 SAE:

SAE=Σ |y_i-ŷ_i| (6)

(4) 决定系数 R^2 (拟合优度):

R^2(y,ŷ)=1-Σ (y_i-ŷ_i)^2 / Σ (y_i-ȳ)^2 (7)

R^2 决定系数越接近 1 表示拟合效果越好。上述公式中 y_i 为 i 时刻用电电器真实功率, $\hat{y}_i$ 为模型分解功率, n_{sample} 为总样本输入数量。

最后,为了表示模型预测值与实际值间的差距,定义损失函数(Loss)表达式如下:

Loss=Σ ln p(X_{t:t+N_i-1} | Y_{t:t+N_i-1}, θ_s) (8)

式中: p 表示概率; T 为序列总长度; X_t 为各设备的功率; Y 为总负荷功率; θ_s 为网络参数; N_i 为第 i 项设备的序列长度。

2.5 实验结果

2.5.1 可视化分解结果

本文选取 REDD 数据集家庭 1 一段时间内的负荷功率进行分解。通过实验结果可视化操作,能够直观地判断模型对各项电器功率的预测效果。由图 3 可以看出,在该段时间内,冰箱电器在训练集和测试集上负荷分解的预测值与真实值基本拟合,初步判断本模型的可行性。




图 3 实验结果可视化展示

2.5.2 负荷识别准确率

通过多次实验比较获得模型的系数。实验中,各模型识别准确度(PRE)结果如表 5 所示。

表 5 各模型识别准确率

模型	准确率/%	提升百分比/%
CNN-LSTM	98.26	—
CNN-1d-2	99.26	1.00
CNN-multi-kernel	99.41	1.15

识别准确率能够反映模型对负荷的识别能力。可以看到三种模型准确率都超过了 98%, 多层单核 (CNN-1d-2) 和多层多核模型 (CNN-multi-kernel) 更是超过了 99%, 其中对照文献 (CNN-LSTM) 深度浅、特征提取能力较弱, 准确率相对较低。而 CNN-multi-kernel 相较于其他模型采用了多层多核网络结构, 特征提取更加充分, 从而获得最高的准确率。

与对照文献相同, 本文也选用了 REDD 数据集 中的冰箱、洗碗机、水壶、微波炉、洗衣机 5 种常用电器数据, 统计了各种电器的相应识别率。具体结果如表 6 所示。

表 6 各模型下不同电器的识别准确率 单位: %

模型	冰箱	洗碗机	水壶	微波炉	洗衣机
CNN-LSTM	97.81	89.13	78.62	97.60	77.75
CNN-1d-2	99.79	98.73	95.41	97.67	82.08
CNN-multi-kernel	99.98	98.29	96.43	98.00	82.15

相比于对照文献, 多层单核模型对各项电器的分解准确率的提升程度为 2%~18%, 多层多核模型分解准确率的提升程度为 3%~19%。其中, 对于洗衣机和水壶等多档运行的电器设备识别准确度提升效果较为明显, 说明多层多核模型对运行方式复杂的电器识别能力更强。

2.5.3 损失函数及误差

本文模型在训练中的损失函数 (Loss)、平均绝对值误差 (MAE)、绝对误差和 (SAE) 和拟合优度 R^2 曲线如图 4 所示, 实线代表整体平均曲线, 虚线代表冰箱数据的曲线。上述指标可以反映模型的负荷功率分解能力。从图 4 可以看出, 随着网络迭代次数的增加, 本文模型在各个电器上训练的损失函数呈现收敛的趋势。以冰箱数据为例, 损失函数收敛十




图 4 loss、MAE、SAE、 R^2 曲线

分平稳, 说明损失函数对神经网络的超参数优化作用明显, 实现了模型超参数的自动寻优。随着迭代次数的增加, 平均绝对值误差 (MAE)、绝对误差和 (SAE) 不断下降, 拟合优度 R^2 曲线不断上升并逐渐收敛至稳定常数, 该三项指标的全面提升表明模型分解得到的功率值与实际功率的真实值间的差距随网络迭代次数逐渐减小。由此可见, 本模型负荷特征提取性能的提升使得负荷识别率得到提高, 与之相应的, 功率分解性能也得到了提升。


3 结束语

本文提出一种基于多层多核卷积神经网络的非侵入式负荷监测深度学习模型, 该模型在提取负荷特征时, 采用多核卷积特征提取法提取负荷功率的多项特征, 并结合多层卷积法增强网络结构。实验结果中各模型识别准确率之间的差异说明, 多核卷积法与多层卷积法都能够增强网络对负荷特征的提取能力, 将两种方法相结合后, 特征提取会更加充分。通过本模型在数据集上的实验结果可以看出模型对负荷识别准确率提升很大, 尤其显著提升了运行状态较复杂的电器识别准确率。同时, 相对于目前认可度较高的 CNN-LSTM 模型, 本模型对负荷分解功率值的平均绝对值误差和绝对误差和也有大幅度的减小, 且拟合优度更高。实验验证了模型不仅仅对负荷识别性能有提升, 对负荷分解性能也有一定程度的提高。

参考文献:

- [1] Linh N V, Arbolea P. Deep Learning Application to Non-Intrusive Load Monitoring[C]//2019 IEEE Milan PowerTech. Milan, Italy: IEEE, 2019:1-5.
- [2] 燕续峰, 翟少鹏, 王治华, 等. 深度神经网络在非侵入式负荷分解中的应用[J]. 电力系统自动化, 2019, 43(1):126-132.
- [3] 刘一铭, 李惠民, 王乐挺, 等. 基于卷积神经网络的非侵入式负荷监测方法[J]. 电测与仪表, 2020:1-7.
- [4] Carratù M, Ferro M, Pietrosanto A, et al. Smart Power Meter for the IoT[C]//2018 IEEE 16th International Conference on Industrial Informatics (INDIN). Porto, Portugal: IEEE, 2018:514-519.
- [5] Hart G W. Nonintrusive Appliance Load Monitoring[J]. Proceedings of the IEEE, 1992, 80(12):1870-1891.
- [6] 柏慧, 王丽丽, 鲁敬, 等. 基于粒子群聚类算法的居民负荷辨识方法[J]. 电力信息与通信技术, 2018, 16(6):13-18.
- [7] 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.
- [8] 郑耀鹏. 特征差异强化算法在非侵入式负荷监测中的应用研究[J]. 机械设计, 2020, 37(S1):43-47.
- [9] Singh S, Majumdar A. Deep Sparse Coding for Non-Intrusive Load Monitoring[J]. IEEE Transactions on Smart Grid, 2018, 9(5):4669-4678.

- [10] Singhal V, Maggu J, Majumdar A. Simultaneous Detection of Multiple Appliances From Smart-Meter Measurements via Multi-Label Consistent Deep Dictionary Learning and Deep Transform Learning [J]. IEEE Transactions on Smart Grid, 2019, 10(3): 2969–2978.
- [11] 刘玲. 基于稳态特征的非侵入式负荷监测算法研究[D]. 广州: 华南理工大学, 2019.
- [12] 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. New York, NY, USA. 2015: 55–64.
- [13] Barsim K S, Yang B. On the Feasibility of Generic Deep Disaggregation for Single-Load Extraction [C]//Proceedings of the 4th International Workshop on Non-Intrusive Load Monitoring. Austin, Texas, USA. 2018: 1–5.
- [14] Sirojan T, Phung B T, Ambikairajah E. Deep Neural Network Based Energy Disaggregation [C]//2018 IEEE International Conference on Smart Energy Grid Engineering (SEGE). Oshawa, ON, Canada. 2018: 73–77.
- [15] Kaselimi M, Doulamis N, Doulamis A, et al. Bayesian-Optimized Bidirectional LSTM Regression Model for Non-Intrusive Load Monitoring [C]//ICASSP 2019–2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Brighton, UK; IEEE, 2019: 2747–2751.
- [16] Rafiq H, Zhang H, Li H, et al. Regularized LSTM Based Deep Learning Model: First Step Towards Real-Time Non-Intrusive Load Monitoring [C]//2018 IEEE International Conference on Smart Energy Grid Engineering (SEGE). Oshawa, ON, Canada: IEEE, 2018: 234–239.
- [17] 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.
- [18] Najafi B, Moaveninejad S, Rinaldi F. Data Analytics for Energy Disaggregation: Methods and Applications [M]//Big Data Application in Power Systems. Elsevier, 2018: 377–408.
- [19] 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. New Orleans, Louisiana, USA. 2018: 2604–2611.
- [20] Liu Y, Wang X, You W. Non-Intrusive Load Monitoring by Voltage-Current Trajectory Enabled Transfer Learning [J]. IEEE Transactions on Smart Grid, 2018, 10(5): 5609–5619.
- [21] D'incenzo M, Squartini S, Zhong M. Transfer Learning for Non-Intrusive Load Monitoring [J]. IEEE Transactions on Smart Grid, 2020, 11(2): 1419–29.
- [22] Nambiar L, KumarGopal V, Pradeep R. Energy Disaggregation for NILM Applications Using Shallow and Deep Networks [C]//2019 IEEE 5th International Conference for Convergence in Technology (I2CT). Bombay, India; IEEE, 2019: 1–6.
- [23] Yang Y, Zhong J, Li W, et al. Semisupervised Multilabel Deep Learning Based Nonintrusive Load Monitoring in Smart Grids [J]. IEEE Transactions on Industrial Informatics, 2019, 16(11): 6892–6902.
- [24] Elhassouny A, Smarandache F. Trends in Deep Convolutional Neural Networks Architectures: A Review [C]//2019 International Conference of Computer Science and Renewable Energies (ICCSRE). Agadir, Morocco; IEEE, 2019: 1–8.
- [25] Kolter J Z, Johnson M J. REDD: A Public Data Set for Energy Disaggregation Research [C]//Workshop on Data Mining Applications in Sustainability (SIGKDD), San Diego, CA, USA. 2011, 25 (Citeseer): 59–62.



汪涛(1996—),男,硕士研究生,通信作者,研究方向为非侵入式负荷识别与分解算法研究,2531730119@qq.com;



梁瑞宇(1978—),男,博士,教授,研究方向为信号识别与处理;



黄虎(1996—),男,硕士研究生,研究方向为电力运行现场安全状态检测;



丁超(1997—),男,硕士研究生,研究方向为电力线路安全检测。