

# 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

刘仲民<sup>1</sup>, 侯坤福<sup>1</sup>, 高敬更<sup>2</sup>, 王治国<sup>2</sup>

(1. 兰州理工大学电气工程与信息工程学院, 兰州市 730050;

2. 国网甘肃省电力公司营销服务中心, 兰州市 730300)

**摘要:** 非侵入式负荷分解技术通过从主表信息中恢复出用电侧单个用电设备的状态, 可以准确地刻画用户用电画像, 为用户侧精细化管理发挥重要作用。针对目前人工神经网络模型在负荷分解中存在的分解精度不高、训练效率低下等问题, 文章构建了基于时间卷积神经网络(temporal convolutional neural network, TCN)的非侵入式负荷分解模型。通过分析设备的用电规律, 采用扩张因果卷积在主表功率序列进行卷积运算, 扩大了感受野, 提取到更加丰富的特征; 通过增加残差连接、权重归一化层, 优化训练数据窗口, 提高了网络训练效率。最后, 在经过优化的UKdale数据集上对构建的模型进行测试, 实验结果表明获得的平均绝对误差、均方根误差、相对误差都处于较小的范围, 时间复杂度分析也进一步说明了在不损失负荷分解精度的情况下, 模型具有较短的训练时间。

**关键词:** 智能电网; 负荷分解; 时间卷积神经网络(TCN); 序列到点

## Non-Intrusive Residential Electricity Load Disaggregation Based on Temporal Convolutional Neural Network

LIU Zhongmin<sup>1</sup>, HOU Kunfu<sup>1</sup>, GAO Jinggeng<sup>2</sup>, WANG Zhiguo<sup>2</sup>

(1. College of Electrical and Information Engineering, Lanzhou University of Technology, Lanzhou 730050, China;

2. Marketing Service Center, State Grid Gansu Electric Power Company, Lanzhou 730300, China)

**ABSTRACT:** Non-intrusive load disaggregation can accurately portray the user's power consumption portrait by recovering the information of single electrical equipment on the power consumption side from the total electric meter information, which plays an important role in the refined management of the consumers. Aiming at the problems of low decomposition accuracy and low training efficiency of current artificial neural network models in load decomposition, this paper studies and builds a non-intrusive load disaggregation model based on temporal convolutional neural network. By analyzing the power consumption of the device, the dilated causal convolution is applied to perform convolution operations on the power sequence of electric meter and to expand the receptive field and extract richer features. The network training efficiency is improved by adding residual connections, weight normalization layers and optimizing training data window. Finally, the constructed model is tested on the optimized UKdale data set. The experimental results show that mean absolute error, root mean square error, and relative error are all in a relatively small range, and the time complexity analysis further shows that the model has a shorter training time without losing the load decomposition accuracy.

This work is supported by the Science and Technology Project of State Grid Gansu Electric Power Research Institute (No. 52273118000Y).

**KEYWORDS:** smart grid; load disaggregation; temporal convolutional neural network(TCN); sequence to point

中图分类号: TM 73

文献标志码: A

文章编号: 1000-7229(2021)03-0097-10

DOI: 10.12204/j.issn.1000-7229.2021.03.012

## 0 引言

非侵入式负荷监测技术(non-intrusive load monitoring, NILM)也称为负荷分解(load

disaggregation), 可将用户总负荷信息分解为各用电设备信息<sup>[1]</sup>。通过分析用电设备能耗情况与用户用电规律等用电信息, 可为用户提供用能状况分析、用能方案优化等多种服务, 从而实现用户内部用能行为的间接管理, 对提高用能效率、节省电能资源具有重要的意义<sup>[2]</sup>。此外, 利用非侵入式负荷分解技术得到的用户

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)

用电信息对于精细配电工作<sup>[3]</sup>、分时电价服务<sup>[4]</sup>、异常用电行为监测<sup>[5]</sup>等任务具有一定的数据参考价值。

非侵入式负荷分解由 G. W. Hart 教授在 20 世纪 80 年代提出<sup>[6]</sup>。主流方法是利用隐马尔可夫模型进行研究<sup>[7-9]</sup>，该类方法包括模型学习和解码 2 个阶段。在学习阶段根据训练数据估计模型参数，使得在该模型下观测序列概率最大；解码阶段根据已估计得到的模型及输入的观测序列，求取给定观测序列条件概率最大的状态序列。由于设备数量及各设备状态数目的不断增加，模型所需处理的状态数量及运算量呈指数级增加，因此模型计算复杂度大大增加<sup>[10]</sup>。近年的研究表明，非侵入式负荷分解问题又可以看做是单通道盲源分离问题，为此英国学者 Kelly 在 2015 年首次将神经网络模型用于解决非侵入式负荷分解问题<sup>[11]</sup>。该模型将输入序列（主表功率序列）通过神经网络强大的非线性映射学习能力映射到输出序列（设备功率序列），取得了较高的负荷分解精度。相比隐马尔可夫模型，神经网络模型计算更为简单，但模型训练效率较低，并且输出序列中的元素被多次预测，边缘将被平滑，也一定程度上影响了分解精度。文献 [12] 在前人的工作基础上，提出了序列到点（sequence-to-point, Seq2point）的学习方式，该方法利用了神经网络学习输入序列和输出点的映射关系，虽然一定程度上提高了分解精度，但仍存在网络模型训练效率低、分解精度不够的问题。

基于上述分析，本文提出一种基于 Seq2point 的改进非侵入式负荷分解方法。首先，利用 Nilmk 工具包对公开数据集进行预处理，并利用滑动窗口方法（窗口长度由对比实验对比得出）生成训练数据，采用零均值归一化完成训练数据归一化。然后，考虑卷积运算并行处理数据更高效的优势<sup>[13]</sup>，针对用电设备的运行特点，采用时间卷积神经网络（temporal convolutional neural network, TCN）架构<sup>[14]</sup>搭建网络。不同于普通卷积的 Seq2point 方法，带膨胀系数的因果卷积可以扩大卷积核感受野，可提取更为丰富的特征；同时引入权重归一化技术进一步提升网络训练效率。最后，将生成的训练数据用于训练改进后的人工神经网络得到负荷分解模型。实验结果表明，本文提出的非侵入式负荷分解方法在提高负荷分解精度的同时，能进一步减少网络训练的时间。

## 1 非侵入式负荷分解模型

### 1.1 非侵入式负荷分解定义

负荷分解是指从入户智能电表信息恢复出单个用电设备功率信息的过程。一般情况下，可以通过智

能电表获得用户一段时间内总的用电信息，如有功率、视在功率等，但无法获得单个用电设备的用电信息。设某住户某段时间  $T$  内的主表功率序列  $Y$  与单个用电设备用电序列  $X_e$  分别为：

$$Y = (y_1, y_2, y_3, \dots, y_t), t \in T \quad (1)$$

$$X_e = (x_{e1}, x_{e2}, x_{e3}, \dots, x_{et}), e \in N, t \in T \quad (2)$$

式中： $y_t$  为  $t$  时刻的主表功率值； $x_{et}$  为用电设备  $e$  在  $t$  时刻的功率值。

非侵入式负荷分解在算法层面构建分解模型，从主表功率序列  $Y$  中分解出单个用电设备的功率序列  $X_e$ 。目前主要的研究集中于提高负荷分解的精度和获得较高的分解速率。

### 1.2 非侵入式负荷分解流程

基于时间卷积神经网络的非侵入式负荷分解流程如图 1 所示。整个过程分为模型训练和调用模型进行负荷分解。

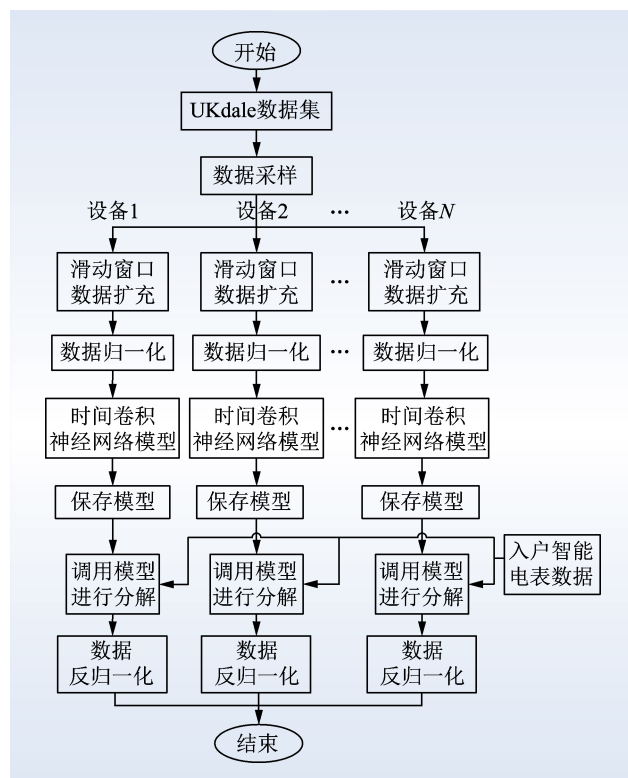


图 1 基于时间卷积神经网络的负荷分解流程

Fig. 1 The process of NILM based on temporal convolutional neural network

在模型训练阶段：首先利用公开数据集制作训练样本，主表功率作为特征数据，用电设备功率作为标签，将处理完成的数据用于时间卷积神经网络的有监督训练，并保存多次迭代训练后的模型。

在负荷分解阶段：将待分解的主表功率序列经数据处理后送入训练得到的模型并输出预测值，经反归一化后得到最终的设备功率值。对于不同的用电设

备 本文分别构建神经网络进行训练,但神经网络结构完全相同,不同之处在于用电设备间训练数据本身各不相同。

### 1.3 扩张因果卷积

为提取更加丰富的特征,本文改进了 Seq2point 特征提取器的设计,采用扩张因果卷积构建特征提取器,具有适应时间序列预测规律及感受野更广大的优点。

Seq2point 采用的普通卷积与本文所提扩张因果卷积的感受野对比如图 2 所示。从图 2 可以看到,同样卷积核大小为 3 时,普通卷积第 3 层的卷积提取的特征仅与输入序列的 7 个时刻相关,且引入了未来时刻信息去预测当前时刻信息,所能提取到的特征极为有限,且不符合时间序列预测规律,因此有必要对特征提取器进行改进。




图 2 普通卷积与扩张因果卷积感受野对比  
Fig. 2 Comparison of the receptive field between ordinary convolution and dilated causal convolution

扩张因果卷积相对于普通卷积有两点不同,由于这种不同才使得扩张因果卷积在时间序列问题上表现更好。

首先,因果卷积  $t$  时刻的输出只与  $t$  时刻以及前几个时刻的输入信息相关,严格遵守时间先后顺序,这意味着在时间卷积神经网络中不会掺杂当前时刻之后的任意信息,确保未来时刻信息不会向待预测的当前时刻点泄露。已知主表功率序列为式(1),则序列中任意时刻点  $t$  的因果卷积  $F(t)$  被定义为:

$$F(t) = (Y * f)(t) = \sum_{i=0}^{k-1} f(i) \cdot Y_{[t-i]} \quad (3)$$

式中:  $f$  代表卷积核;  $k$  为卷积核尺寸;  $i$  代表卷积核中的元素;  $t$  为主表功率序列中的第  $t$  个时刻;  $Y_{[t-i]}$  为与卷积核做运算的主表功率值。

实际应用中,当前时刻用电设备的运行状态大致会跟前一个或几个时刻的运行状态相关。以冰箱为例,冰箱运行特性如图 3 所示,冰箱的压缩机在启动时会具有较大的冲击电流,该时刻的功率会瞬间增加,然后是较为平稳的运行阶段,在工作一段时间后,压缩机停止运行,一段时间后,压缩机重新启动,再次

产生冲击点,设备周期运行,具有典型的时间先后顺序。利用因果卷积进行特征提取时,会学习出这种先冲击后平稳再关闭的运行特征,便于从主表功率中分解出设备的功率信息。




图 3 冰箱运行特性  
Fig. 3 Refrigerator operating characteristic

另一方面,因果卷积虽然能更好地对时间序列问题进行建模,但该方式与普通卷积存在同样的问题:所提取的特征仅考虑了邻近前几个时刻的信息,长时运行设备(如洗衣机具有 2~3 h 的运行时间)在更久远时刻也具有特征信息,但限于感受野不足,故无法提取这类信息,影响分解精度。为改善感受野不足问题,在因果卷积中注入“空洞”,从而可以追溯到更久远时刻的功率信息。在  $Y$  处的扩张因果卷积<sup>[15]</sup>被定义为:

$$F(t) = (Y *_{d} f)(t) = \sum_{i=0}^{k-1} f(i) \cdot Y_{[t-di]} \quad (4)$$

式中:  $d$  是膨胀系数,通过向卷积核中注入“空洞”,可以与之前时刻的时序点做卷积操作。当  $d=1$  时,膨胀卷积等效于普通因果卷积;当  $d=2$  时,滤波器所能接受的输入相较于普通因果卷积从  $1 * 3$  扩大到  $1 * 5$ ,同时对比普通卷积,第三卷积层提取到的特征点可以追溯至输入序列的前 14 个时刻,对时间维度上的信息回溯更久远。因此,本文采用扩张因果卷积对原有特征提取器进行改进。

### 1.4 权重归一化技术

利用神经网络对非侵入式负荷分解建模时,需要训练的参数数量庞大,极其耗费计算机资源,有必要引入一系列的优化手段加速网络训练。

利用归一化技术重写神经网络中的参数可使模型目标损失函数更加平滑,加速随机梯度下降优化算法的收敛过程,因而能提升网络训练效率<sup>[16]</sup>。权重归一化技术是一种重写权重向量  $w$  的参数重写

方法。

标准神经元中的计算为:

$$y = \varphi(w \cdot x + b) \quad (5)$$

式中:  $w$  为  $k$  维权重向量;  $b$  为标量偏差项;  $x$  为输入特征的  $k$  维向量;  $\varphi(\cdot)$  表示非线性激活函数;  $y$  表示神经元的标量输出。在将损失函数与一个或多个神经元输出相关联之后,通常通过随机梯度下降,在每个神经元的参数  $w$ 、 $b$  中训练神经网络。为了加快此优化过程的收敛速度,利用参数向量  $v$  和标量参数  $g$  重新参数化每个权重向量  $w$ ,则有:

$$w = \frac{g}{\|v\|} v \quad (6)$$

根据新参数表示权重向量,其中  $v$  是  $k$  维向量  $g$  是标量且  $\|w\| = g$ ,  $\|v\|$  表示  $v$  的欧几里得范数。

将权重向量  $w$  重新参数化以后,梯度下降将更新  $v$  与  $g$  不再是  $w$ ,该推导过程及原理限于篇幅不再赘述,具体可参考文献[16]。

### 1.5 网络构建

文献[14]中所提结构为通用时间序列问题建模模型,通用模型中,时间卷积神经网络输入层采用一维全卷积,采用双层扩张因果卷积组成一个残差块,卷积层之间添加权重归一化层、Dropout层<sup>[17]</sup>。残差块作为基本单元用于搭建时间卷积神经网络,为了防止训练中梯度消失,在残差块之间引入跳层连接<sup>[18]</sup>。

经过实验发现通用结构用于负荷分解时,模型较为复杂,耗费计算资源,且分解效果不佳,因此本文简化通用结构,通过大量测试,设计了适于非侵入式负荷分解任务的简化时间卷积神经网络。

首先采用扩张因果卷积为基本层构建特征提取器,在每层卷积层之间引入权

重归一化层,保留 Dropout 层,同时在网络中引入残差连接,然后采用全连接神经网络完成用电设备功率的预测。图4给出了本文所提简化时间卷积神经网络的具体结构及参数。

## 2 数据获取及处理

### 2.1 数据集

数据集采用英国能源研究中心(UK Energy Research Center, UKERC) 2015年公开发布的UKdale数据集<sup>[19]</sup>。UKdale数据集记录了从2012年11月到2015年1月中5个家庭的用电数据。数据集包含了10多种类型的电器,每6s采集一次用电数据。家用电器种类繁多,为了验证模型对于不同运行特性电器设备的有效性,在本文设计的实验中,选取水壶、电视机、冰箱、洗碗机和洗衣机这5类设备。这是因为:冰箱的运行特征具有周期性特点;相比冰箱,洗衣机、洗碗机的工作模式更为丰富,运行特征较为复杂;水壶运行功率大、时间周期短;电视机功率小,单次运行时间较长。表1为算例分析所用设备及其具体采样时间段。

### 2.2 数据预处理及生成

数据预处理过程分为实验数据提取和处理缺失值。利用 Nilmk 工具包<sup>[20]</sup>将原始数据转化为可用于科学计算的数据格式。同时,设置相应的实验数据时间段并重新采样,如果部分时间段数据缺失,将被删除。为进一步提高模型训练效率,本文利用滑动窗口的方法扩充数据,制定相对应的主表功率序列以及用电设备功率标签。滑动窗口在给定的样本数据上进行步长为1的滑动,每一次滑动窗口将会产生一组数据。

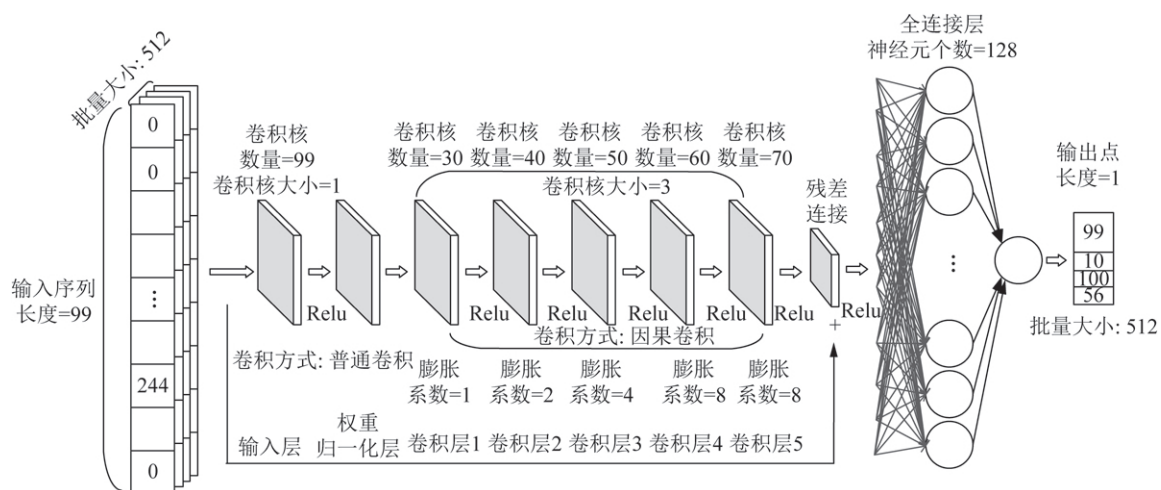


图4 时间卷积神经网络结构

Fig. 4 Structure of temporal convolutional neural network

表 1 数据分配表  
Table 1 Data configuration

电器	训练数据时间段	测试数据时间段
冰箱	2013-07-01—2013-09-30	2014-07-21 T 00:18:00—2014-07-21 T 06:40:00
洗衣机	2013-07-01—2013-09-30	2014-07-12 T 12:15:00—2014-07-12 T 13:30:00
洗碗机	2013-07-01—2013-09-30	2014-06-05 T 12:16:00—2014-06-05 T 13:50:00
电视机	2013-07-01—2013-09-30	2014-06-24 T 15:35:00—2014-06-24 T 22:30:00
水壶	2013-07-01—2013-09-30	2014-06-27 T 16:10:00—2014-06-27 T 18:00:00

本文重点关注了窗口长度对模型训练及负荷分解精度的影响,通过大量实验发现,较大和较小的窗口会影响负荷分解效果与模型训练效率。文献[12]所提的 Seq2point 方法全设备采用了窗口长度为 599 的设定,本文方法依据大量实验结果择优重新设定滑动窗口的长度,选取每种设备的平均绝对误差(mean absolute error, MAE)  $M_{mae}$  值最小的窗口长度用于生成数据(如洗碗机窗口长度为 99),从而保证在不影响分解精度的情况下,进一步减少模型训练时间。表 2 展示了各类设备 20 次迭代训练中不同窗口长度 Seq2point 方法的训练时间及  $M_{mae}$  指标。

表 2 不同窗口长度实验结果对比

Table 2 Experimental results of different window lengths

窗口长度	$M_{mae}$					训练耗时/s
	冰箱	洗衣机	洗碗机	水壶	电视机	
39	8.97	69.28	63.67	57.82	20.49	16
99	9.25	90.11	41.56	53.54	15.69	46
299	13.34	168.16	280.28	75.26	20.04	96
599	16.58	173.11	252.59	80.45	24.14	191

图 5 展示了滑动窗口的工作过程。数据完全生成后利用零均值归一化方式对数据做归一化处理,便于神经网络模型的训练。计算方法为:

$$T_1 = \frac{M_{data} - M_{mean}}{M_{std}} \quad (7)$$

$$T_2 = \frac{A_{data} - A_{mean}}{A_{std}} \quad (8)$$

式中:  $T_1$ 、 $T_2$  分别为归一化后的主表功率和用电设备功率;  $M_{data}$  为主表原始数据;  $M_{mean}$  为主表功率序列的均值;  $M_{std}$  为主表功率序列的标准差;  $A_{data}$  为用电设备原始数据;  $A_{mean}$  为用电设备功率的均值;  $A_{std}$  为用电设备序列和功率的标准差。

### 3 实例分析

#### 3.1 实验环境

本文硬件环境为 Intel(R) CoreTM i7-7700CPU @ 3.6 GHz, 16 GB DDR4 内存及 GeForce GTX 1070(8 GB




图 5 滑动窗口数据扩充示意图  
Fig. 5 Schematic diagram of sliding window for data augmentation

显存) 的 64 位计算机。软件平台为 WINDOWS-10 专业版操作系统, Python 3.6.2 (64 位) 及 TensorFlow1.8.0 深度学习框架。在训练深度学习模型时使用 TensorFlow 的 GPU 版本, 利用 GPU 进行硬件加速。

#### 3.2 实验设计

为了验证本文方法的效果, 与基于循环神经网络(recurrent neural network, RNN) 方法、降噪自编码器(denoising autoencoder, DAE) 方法以及 Seq2point 方法进行对比; 实验中所提模型均按照原论文作者所提结构搭建, 包括输入序列长度、卷积核个数及卷积核大小、卷积层数等。为了客观对比各类算法的性能, 采取了多类设备进行算法性能测试, 包含验证模型的分解性能、模型的泛化性能、模型的训练耗时。

#### 3.3 评价指标

本文所使用的评价指标包括: F1 分数(F1 score)  $F_{Score}$ 、均方根误差(root mean square error, RMSE)  $M_{rmse}$ 、 $M_{mae}$  和总能量相关误差(relative error, RE)  $M_{re}$ , 具体计算方法为:

$$F_{Score} = \frac{2PR}{P + R} \quad (9)$$

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}} \quad (10)$$

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}} \quad (11)$$

$$M_{rmse} = \sqrt{\frac{1}{T} \sum_{i=1}^T (\hat{x}_i - x_i)^2} \quad (12)$$

$$M_{\text{mae}} = \frac{1}{T} \sum_{t=1}^T | \hat{x}_t - x_t | \quad (13)$$

$$M_{\text{re}} = \frac{| \hat{E} - E |}{\hat{E}} \quad (14)$$

式中:  $P$  为准确率;  $R$  为召回率;  $N_{\text{TP}}$  表示负荷在真实数据中打开而在预测中也打开时的总数;  $N_{\text{FP}}$  表示负荷在真实数据中关闭而在预测中打开时的总数;  $N_{\text{FN}}$  表示负荷在真实数据中打开而在预测中关闭时的总数;  $\hat{x}_t$  与  $x_t$  分别表示设备在时间  $t$  的预测功率与真实功率;  $T$  代表时间序列采样点区间长度;  $\hat{E}$  表示总预测能量;  $E$  表示实际总能量。

$M_{\text{mae}}$  可以验证所提方法得出的分解预测值跟实际设备运行值的差距;  $M_{\text{rmse}}$  与  $M_{\text{mae}}$  相似, 但对异常的预测值更为敏感, 当出现某个时刻分解预测值与实际运行值相差较大时,  $M_{\text{rmse}}$  的值会更大;  $F_{\text{Score}}$  更加侧重于评价设备运行状态(设备开启或关闭), 而不是设备实际运行的功率值大小, 分数越高代表性能越好;  $M_{\text{re}}$  用于评价该段时间内预测误差占预测总能量的比值。

### 3.4 分解效果对比

图6为利用1号家庭的3个月用电数据进行训练, 并且在1号家庭中进行测试所得结果。

从图6中可以看出, 本文所提基于时间卷积神经网络负荷分解方法相比其他方法更加接近冰箱实际的运行效果, 虽然在部分时间采样点有一定的偏差, 但是相较于其他方法, 本文所提方法在整体上较好地预测了电器运行的规律及趋势。1号家庭冰箱负荷分解评价指标对比见表3。由表3可以看出, 本文所提TCN方法的  $M_{\text{mae}}$ 、 $M_{\text{rmse}}$  及  $M_{\text{re}}$  都处于较小的范围, 误差值大小反映了通过算法分解得到的设备功率值与真实功率值之间的差距。洗衣机、洗碗机、电视机与水壶的负荷实验结果及评价指标对比见附录A。

表3 1号家庭冰箱负荷分解评价指标对比  
Table 3 Comparison of evaluation indices of refrigerator load monitoring in household 1

方法	$M_{\text{mae}}$	$M_{\text{rmse}}$	$M_{\text{re}}$	$F_{\text{score}}$
DAE	17.61	31.43	0.47	0.89
RNN	6.02	16.96	0.37	0.96
Seq2point	10.11	15.56	0.49	0.98
TCN	5.05	10.04	0.31	0.99

### 3.5 模型泛化性能对比

图7为利用2、4、5号家庭的数据训练并且在1号家庭中测试冰箱设备所得结果, 表4为模型泛化能力测试的评价指标对比。对比图7和表4, 所有分解模型负荷分解精度均有所下降, 但本文所提方法仍然




图6 家庭1冰箱负荷分解实验结果对比  
Fig. 6 Comparison of experimental results of refrigerator load monitoring in household 1

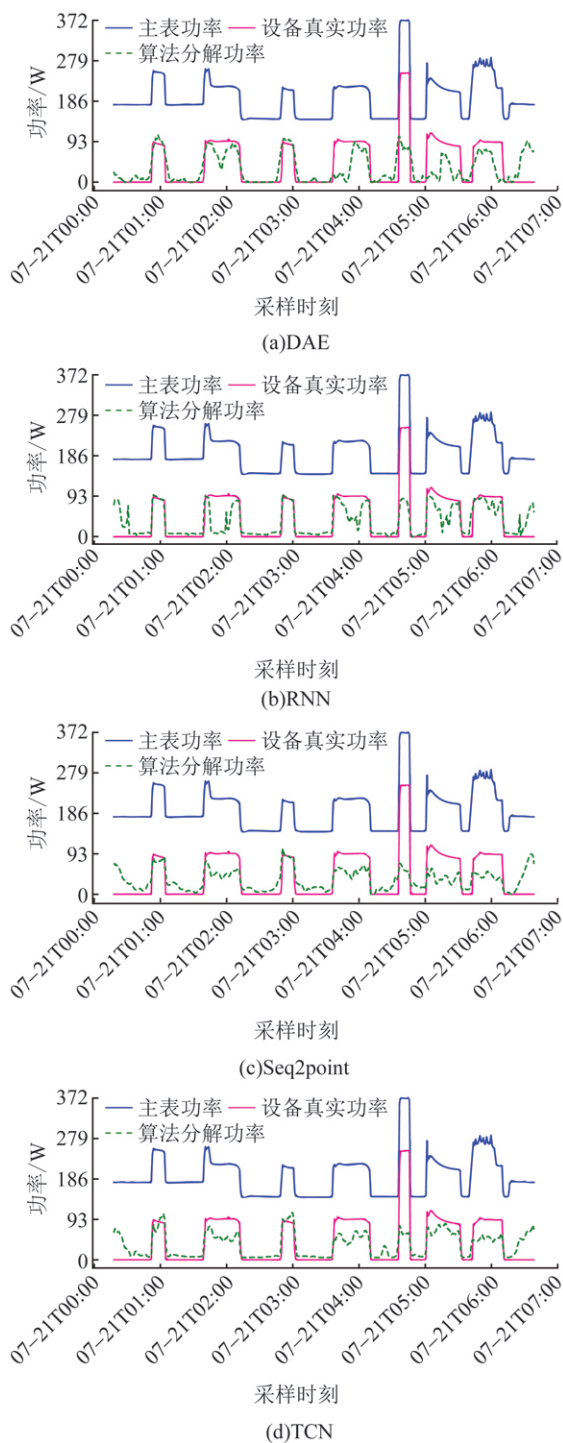


图 7 跨家庭模型泛化能力实验结果对比  
Fig. 7 Comparison of experimental results of generalization ability of models across households

表 4 跨家庭冰箱负荷分解评价指标对比  
Table 4 Comparison of evaluation indices of refrigerator load monitoring across households

方法	$M_{mae}$	$M_{rmse}$	$M_{re}$	$F_{score}$
DAE	27.54	45.62	2.01	0.71
RNN	22.91	40.41	1.05	0.79
Seq2point	32.01	45.96	0.97	0.62
TCN	26.71	41.33	0.84	0.81

较好地预测了功率变化的趋势,但是由于每个家庭之间的冰箱运行耗能情况存在差异,因此对于整个设备的具体功率预测存在一定偏差,属于可以接受的范围。

### 3.6 时间复杂度分析

模型的训练将会极大地消耗计算资源,出于环保角度和运行效率的考虑,有必要对模型训练的时间进行分析。表 5 给出了利用家庭 1 中 3 个月训练数据的训练时间。从表 5 可以看出,同等训练迭代次数情况下,本文所提方法在不损失负荷分解精度情况下,相比 RNN 方法训练消耗的时间减少 50%,这是因为 RNN 方法采用的循环神经网络在处理时序问题时需要严格控制时序,严重影响训练效率,而卷积神经网络可以并行处理时间序列,可提高训练效率;相比于 DAE 方法,TCN 模型训练时间并不占优,这是由于 DAE 方法模型更为简单,但 TCN 方法分解效果更好;相比 Seq2point 方法,TCN 训练时间减少 59.5%,这是因为在网络设计中引入了权重归一化技术对网络训练加速,同时本文采用了最优窗口长度的滑动窗口方法生成训练数据,相比 Seq2point 方法计算量大幅下降,从而提高了模型训练效率。

表 5 训练时间(利用家庭 1 中 3 个月训练数据)  
Table 5 Comparison of training time (3 months training data from household 1)

方法	训练时间/s		
	训练 20 次	训练 50 次	训练 100 次
DAE	13	39	51
RNN	136	347	646
Seq2point	180	450	736
TCN	15 ~ 59	65 ~ 214	135 ~ 298

## 4 结 论

1) 针对现有模型分解精度不高的问题,本文采用扩张因果卷积构建特征提取器,通过向卷积核注入“空洞”扩大了单个卷积核的感受野,由于因果卷积不会夹杂未来时刻信息去预测未来,而普通卷积会引入未来信息预测未来时刻,不符合预测的实际认知,因此因果卷积比普通卷积更符合时间序列问题,能提取更加丰富的特征,提高负荷分解精度。

2) 针对现有神经网络模型训练耗时较长的缺陷,本文提出以下两点改进措施:

(1) 将权重归一化技术应用于优化神经网络模型,使得目标损失函数更加平滑,加速了网络训练的收敛过程,从而提高了模型的训练效率。该加速技术可作为基准方法推广于其他基于神经网络模型的非

侵入式负荷分解方法。

(2) 经过大量的窗口长度对比实验,重新设置窗口序列长度,不同设备采用了最优的窗口长度生成训练数据,在不损失负荷分解精度的情况下,极大提高了模型的训练效率。

仿真实验表明:本文提出的模型在训练速度上比RNN模型提高了50%,比未改进的Seq2point提高了59.5%,同时本文所提方法在评价指标 $M_{mae}$ 、 $M_{rmse}$ 、 $M_{re}$ 、 $F_{score}$ 方面也优于其他方法。

## 5 参考文献

- [1] 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.  
YU Yixin, LIU Bo, LUAN Wenpeng. Nonintrusive residential load monitoring and decomposition technology [J]. Southern Power System Technology, 2013, 7(4): 1-5.
- [2] 程祥,李林芝,吴浩,等.非侵入式负荷监测与分解研究综述[J].电网技术,2016,40(10):3108-3117.  
CHENG Xiang, LI Linzhi, WU Hao, et al. A survey of the research on non-intrusive load monitoring and disaggregation [J]. Power System Technology, 2016, 40(10): 3108-3117.
- [3] 徐大青,栾文鹏,王鹏,等.智能电表数据分析方法及应用[J].供用电,2015,32(8):25-30.  
XU Daqing, LUAN Wenpeng, WANG Peng, et al. Analysis and applications of smart meter data [J]. Distribution & Utilization, 2015, 32(8): 25-30.
- [4] 阮文骏,王蓓蓓,李扬,等.峰谷分时电价下的用户响应行为研究[J].电网技术,2012,36(7):86-93.  
RUAN Wenjun, WANG Beibei, LI Yang, et al. Customer response behavior in time-of-use price [J]. Power System Technology, 2012, 36(7): 86-93.
- [5] 庄池杰,张斌,胡军,等.基于无监督学习的电力用户异常用电模式检测[J].中国电机工程学报,2016,36(2):379-387.  
ZHUANG Chijie, ZHANG Bin, HU Jun, et al. Anomaly detection for power consumption patterns based on unsupervised learning [J]. Proceedings of the CSEE, 2016, 36(2): 379-387.
- [6] HART G W. Nonintrusive appliance load monitoring [J]. Proceedings of the IEEE, 1992, 80(12): 1870-1891.
- [7] 卢天琪.结合事件检测的HMM非侵入式电力负荷监测算法研究[D].武汉:华中科技大学,2017.  
LU Tianqi. Research on event-based HMM for non-intrusive electrical load monitoring algorithm [D]. Wuhan: Huazhong University of Science and Technology, 2017.
- [8] 吴瑶.基于因子隐马尔科夫模型的非侵入式负荷分解方法[D].北京:华北电力大学,2019.  
WU Yao. Non-intrusive load decomposition method based on factorial hidden Markov model [D]. Beijing: North China Electric Power University, 2019.
- [9] 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.
- [10] 邓晓平,张桂青,魏庆来,等.非侵入式负荷监测综述[J/OL].自动化学报:1-20 [2020-09-07]. <https://doi.org/10.16383/j.aas.c200270>.
- [11] 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, USA: ACM, 2015: 55-64.
- [12] ZHANG C Y, ZHONG M J, WANG Z Z, et al. Sequence-to-point learning with neural networks for nonintrusive load monitoring [DB/OL]. [2020-07-10]. <http://homepages.inf.ed.ac.uk/csutton/publications/aaai18nilm.pdf>.
- [13] WANG K, LI K L, ZHOU L Q, et al. Multiple convolutional neural networks for multivariate time series prediction [J]. Neurocomputing, 2019, 360: 107-119.
- [14] BAI S, KOLTER J Z, KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling [db/OL]. [2020-07-10]. <https://arxiv.org/pdf/1803.01271.pdf>.
- [15] VAN DE OORD A, DIELEMAN S, ZEN H, et al. WaveNet: A generative model for raw audio [DB/OL]. (2016-09-19) [2020-07-10]. <https://arxiv.org/abs/1609.03499>.
- [16] SALIMANS T, KINGMA D P. Weight normalization: A simple reparameterization to accelerate training of deep neural networks [C]//Proceedings of the 30th International Conference on Neural Information Processing Systems. New York: Curran Associates Inc., 2016: 901-909.
- [17] SRIVASTAVA N, HINTON G, KRIZHEVSKY A, et al. Dropout: A simple way to prevent neural networks from overfitting [J]. Journal of Machine Learning Research, 2014, 15: 1929-1958.
- [18] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA: IEEE, 2016: 770-778.
- [19] 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: 150007.
- [20] 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. Cambridge, UK, 2014: 265-276.

收稿日期:2020-08-13

作者简介:

刘仲民(1978)男,博士,副教授,主要从事智能电网、复杂系统的控制理论与技术等方面的研究工作;

侯坤福(1995)男,硕士研究生,主要从事大数据与智能电网技术方面的研究工作;

高敬更(1984)男,博士,高级工程师,主要从事电能计量技术与管理方面的工作;

王治国(1990)男,工程师,主要从事电能计量方面的研究工作。

(编辑 景贺峰)



附录 A

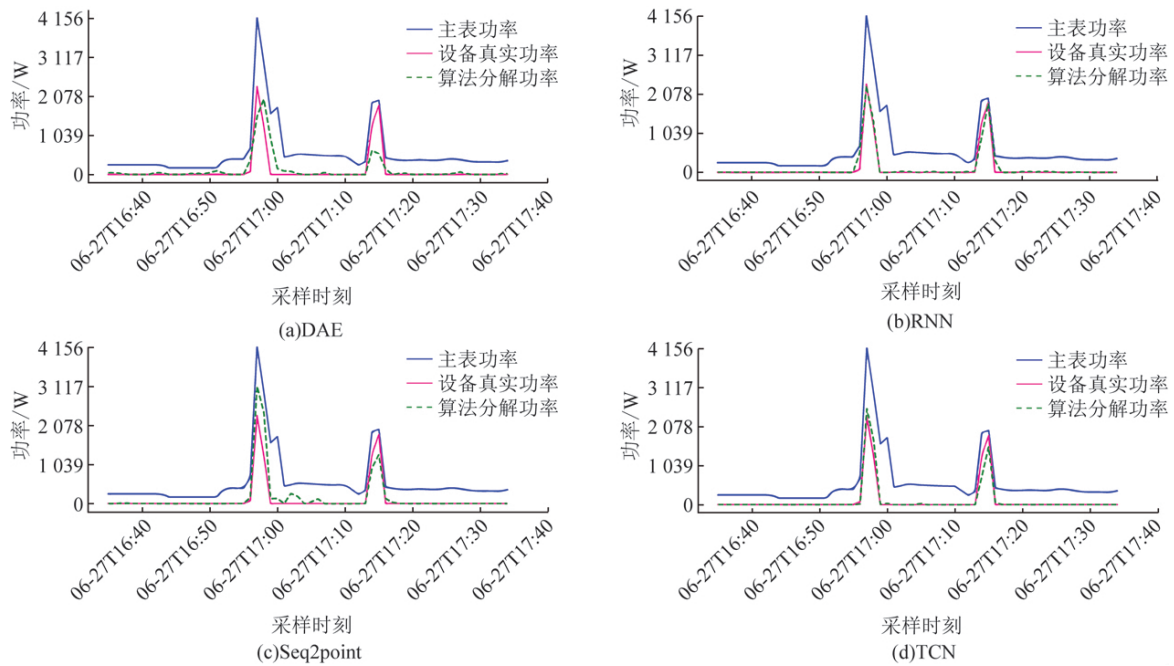


图 A1 水壶实验结果对比显示  
Fig. A1 Comparison of kettle experiment result

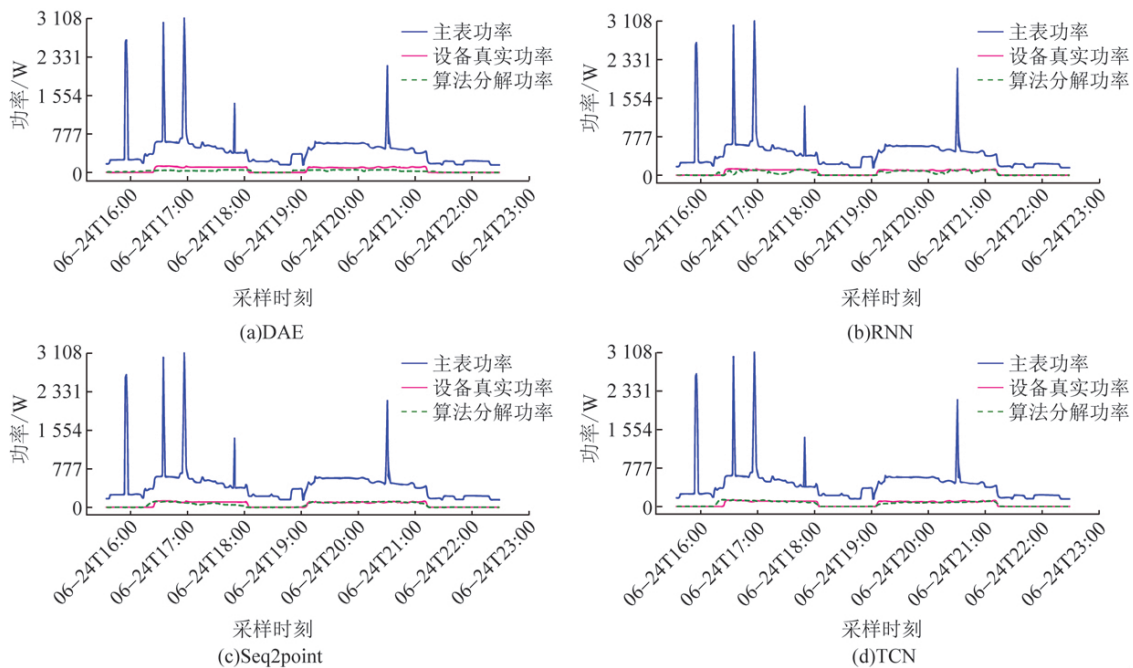


图 A2 电视机实验结果对比  
Fig. A2 Comparison of TV experiment results

表 A1 水壶评价指标对比

Table A1 Comparison of kettle evaluation index

方法	$M_{mae}$	$M_{rmse}$	$M_{re}$	$F_{score}$
DAE	74.67	198.59	0.91	0.62
RNN	55.32	187.66	0.79	0.83
Seq2point	95.72	274.54	0.91	0.48
TCN	41.43	172.58	0.55	0.73

表 A2 电视机评价指标对比

Table A2 Comparison of TV evaluation index

方法	$M_{mae}$	$M_{rmse}$	$M_{re}$	$F_{score}$
DAE	39.47	49.81	1.22	0.61
RNN	17.63	30.26	0.82	0.91
Seq2point	14.84	25.96	0.93	0.95
TCN	12.27	23.23	0.33	0.97

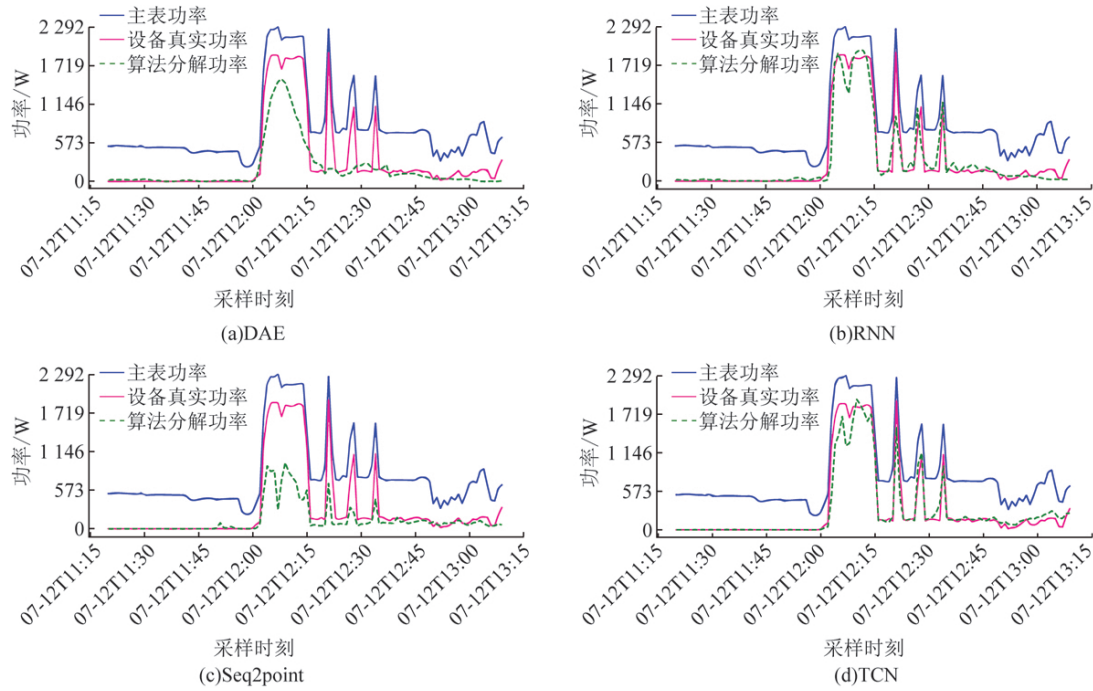


图 A3 洗衣机实验结果对比显示

Fig. A3 Comparison of washing machine experiment results

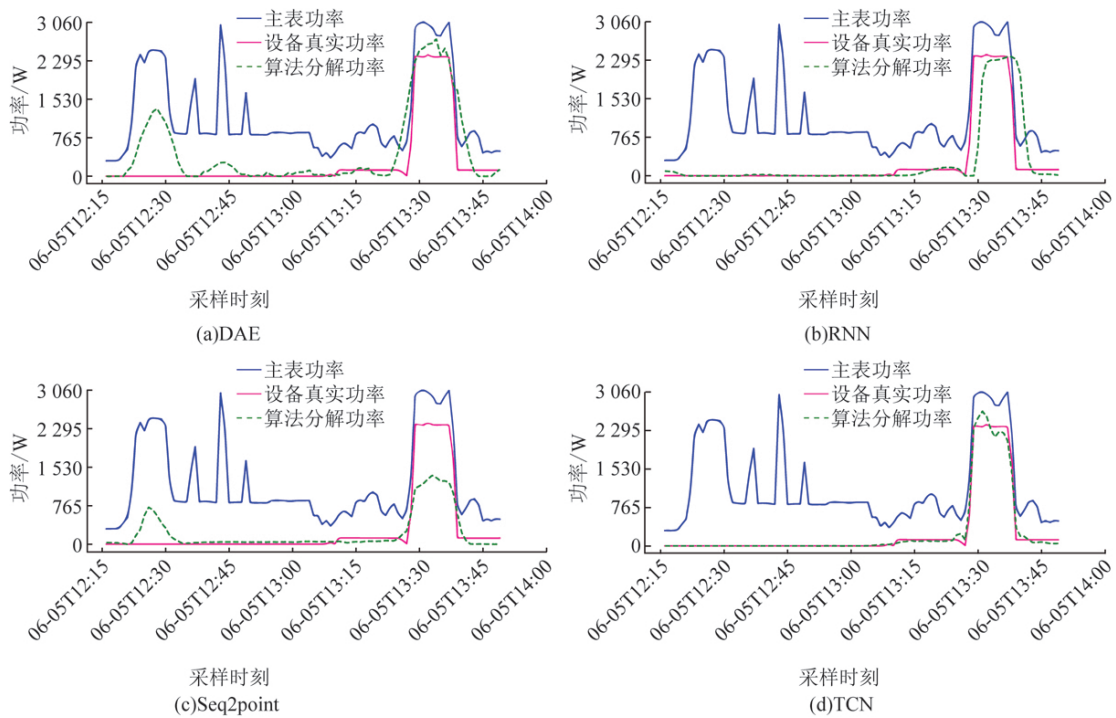


图 A4 洗碗机实验结果对比

Fig. A4 Comparison of dish washer experiment results

表 A3 洗衣机评价指标对比

Table A3 Comparison of washing machine evaluation index

方法	$M_{mae}$	$M_{rmse}$	$M_{re}$	$F_{score}$
DAE	163.04	337.13	7.62	0.86
RNN	86.98	183.52	1.51	0.89
Seq2point	190.49	415.56	0.99	0.91
TCN	66.91	144.14	0.39	0.94

表 A4 洗碗机评价指标对比

Table A4 Comparison of dish washer evaluation index

方法	$M_{mae}$	$M_{rmse}$	$M_{re}$	$F_{score}$
DAE	244.88	449.89	6.52	0.61
RNN	145.92	454.73	33.65	0.73
Seq2point	208.57	395.72	5.42	0.61
TCN	38.13	76.04	0.41	0.97