

## 基于 STE-TCN 的中短期电力负荷预测

郑晓亮<sup>1</sup>, 束庆宇<sup>2</sup>

1. 安徽理工大学 电气与信息工程学院, 安徽 淮南 232001

2. 安徽理工大学 人工智能学院, 安徽 淮南 2320001

**摘要:**目的 针对传统电力负荷预测模型对长序列预测精度低的问题, 提出一种结合跳级卷积连接与时间编码网络的新型时序卷积神经网络(TCN)模型——STE-TCN 模型。方法 首先对 TCN 模型加入跨周期的膨胀卷积通道(Skip-convolution)提取电力数据周期信息; 再进行特征融合得到 Skip-TCN 网络, 使网络抓取周期规律, 增加信息利用长度; 最后设计日期编码网络(Time encoding network)捕捉生活周期和季节性特征, 与 Skip-TCN 进行特征融合得到 STE-TCN 模型, 实现对电力负荷数据长序列预测。结果 实验表明: 在与 TCN 模型和传统时序网络的对比下, Skip-TCN 的预测精度均有提升, 在预测长度更长的测试上提升尤为明显。结论 实验结果验证了通过对更长跨度时序关系的捕捉, STE-TCN 网络改进方法有效提升了长序列电力负荷的预测精度。

**关键词:** 中短期负荷预测; 长序列预测; 时序卷积网络; 周期性关系; 日期编码

中图分类号: TP183 文献标识码: A doi:10.16055/j.issn.1672-058X.2024.0006.007

### Short- and Medium-term Power Load Forecasting Based on STE-TCN

ZHENG Xiaoliang<sup>1</sup>, SHU Qingyu<sup>2</sup>

1. School of Electrical and Information Engineering, Anhui University of Science and Technology, Anhui Huainan 2320001, China

2. School of Artificial Intelligence, Anhui University of Science and Technology, Anhui Huainan 2320001, China

**Abstract: Objective** In response to the problem of low prediction accuracy of traditional power load forecasting models for long sequences, a novel temporal convolutional neural network (TCN) model called STE-TCN, combining skip-level convolutional connections and time encoding networks, was proposed. **Methods** Firstly, skip-convolution channels across periods were added to the TCN model to extract cycle information from power data. The Skip-TCN network was obtained by fusing the features, so that the network captures the cycle pattern and increases the length of information utilization. Finally, the time encoding network was designed to capture the life cycle and seasonal features, and the STE-TCN model was obtained by fusing the features with the Skip-TCN. The long sequence prediction of power load data was realized. **Results** Experimental results show that compared with the TCN model and traditional sequential networks, Skip-TCN exhibited improved prediction accuracy, especially in longer prediction tests. **Conclusion** Experimental results validate that by capturing longer-spanned temporal relationships, the improved method of STE-TCN network effectively enhances the prediction accuracy of long sequence power load data.

**Keywords:** short- and medium-term load forecasting; long sequence prediction; temporal convolutional network; periodic relationships; time encoding

收稿日期: 2023-06-20 修回日期: 2023-08-17 文章编号: 1672-058X(2024)06-0059-06

基金项目: 安徽省自然科学基金(2108085UD07).

作者简介: 郑晓亮, 男(1979—), 安徽淮南人, 博士, 教授, 从事矿山机电系统监测、光电信息处理和煤矿安全监测监控研究。

通讯作者: 束庆宇, 男(2000—), 安徽六安人, 硕士研究生, 从事时序预测、故障诊断研究。Email: 3491691190@qq.com.

引用格式: 郑晓亮, 束庆宇. 基于 STE-TCN 的中短期电力负荷预测[J]. 重庆工商大学学报(自然科学版), 2024, 41(6): 59-64.

ZHENG Xiaoliang, SHU Qingyu. Short- and medium-term power load forecasting based on STE-TCN[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2024, 41(6): 59-64.

## 1 引言

中短期电力负荷预测对于维持电力系统的负荷平衡和稳定运行起到重要作用<sup>[1-2]</sup>。在电力预测中,同样时间跨度下细粒度的预测结果能提供更多的细节信息,其不仅能表现出大致趋势,还能清晰反映出未来中短期内的负荷波动情况,对未来的辅助决策提供更详细的信息<sup>[3]</sup>。但预测粒度的细化,会导致预测和所需处理的序列长度增加。面对序列长度增加的情况,现有预测模型的预测精度难以保证。

长序列时序预测,往往要求模型能从输入序列中挖掘更长跨度的时序关系。传统循环神经网络(Recurrent Neural Network, RNN),通过循环网络单元的结构特点拟合序列中的时序关系,在时序预测问题中取得了良好表现。但循环结构中反向传播的梯度衰减问题,导致了历史信息的遗忘,使模型难以建立序列中相对位置较长数据点之间的时序关系。为了克服这一问题,学者提出了长短期记忆网络(Long Short-Term Memory, LSTM)<sup>[4]</sup>,其在循环结构中加入了遗忘门、输入门和输出门机制,有效提升了网络的记忆长度。近年来,LSTM 模型被应用于负荷预测任务并提出了多种改进模型<sup>[5-8]</sup>,其预测精度大幅提升但预测长度也存在瓶颈。虽然 LSTM 对循环结构的改进增加了模型记忆长度,但并没有彻底解决循环结构带来的遗忘问题。文献[3]通过实验证明预测数据点超过 48 个之后,LSTM 网络性能出现较大差距,此时均方方差(Mean Squared Loss, MSE)上升到不理想的状态,推断速度急剧下降,LSTM 模型开始失效。为解决 RNN、LSTM 等循环网络自身结构带来的遗忘问题,突破记忆长度的限制,不同于循环结构的网络模型被引入时序预测领域<sup>[9-11]</sup>,文献[12]使用时序卷积神经网络(Temporal Convolutional Network, TCN)<sup>[12]</sup>实现负荷预测,卷积的形式使得网络训练反向传播时对于所有输入都是同样的传播距离,打破了输入序列长度的瓶颈。文献[13]在 TCN 的基础上改进了多种时间尺度输入的 TCN 网络(Multi-temporal-spatial-scale Temporal Convolutional Network, MTCN),实验证明采用多尺度输入,可以有效提高网络的预测精度,增强网络对时域特征的提取能力<sup>[13]</sup>。文献[14]在此基础上引入变分模态分解(Variational Mode Decomposition, VMD),将负荷历史数据进行模态分解,然后送入上述多尺度时域卷积中,分别进行预测,接着利用余弦退火算法(Cosine Annealing, COSA)进一步优化网络参数,构建基于 VMD 的 MTCN 预测方法<sup>[14]</sup>。通过数据分解的方式从电力负荷数据复杂时间模式中分解出不同成分,进一步提高了预测精度。但以上根据 TCN 模型进行的改进,网络结构本身都存在感受野不足,并没有充分利用输入序列的问题,对于历史数据的规律挖掘仅停留在短期时序特征的多尺度上,应用于长序列预测依旧有

待改善。

为避免循环结构在长序列预测中的缺陷,本文选取 TCN 网络作为基础网络,结合现有方法改进长序列预测的不足,提高模型长期时序特征学习能力,增加历史信息利用长度,提出一种跨周期连接的卷积分支通道(Skip-Conv),并与原始 TCN 卷积通道进行特征融合得到 Skip-TCN 模型。通过对相差整数周期的数据进行卷积,提取周期特征,实现更长时序关系的捕捉。考虑到电力负荷存在季节性,且与生活周期关系紧密,本文进一步提出了日期编码网络(Time Encoding Net),将 Skip-TCN 网络提取融合日期的编码输出向量,得到 STE-TCN(Skip-Conv-Time Encoding-TCN),通过结合生活周期信息,进一步提升预测长度。最后利用全连接网络,实现长序列的电力负荷中短期预测。

## 2 STE-TCN 网络设计与改进

### 2.1 时序卷积神经网络(TCN)

TCN 是一种处理时域信息的一维卷积神经网络,网络结构由膨胀因果卷积堆叠组成,卷积块之间由残差连接,可以解决梯度消失问题从而加深网络。膨胀因果卷积(图 1),即在因果卷积上加入膨胀卷积的间隔采样方法。




图 1 膨胀因果卷积

Fig. 1 Expansive causal convolution

在一个  $n$  层的一维卷积网络中,卷积核大小设为  $k$ ,步长为 1,其网络感受野大小为

$$r = 1 + n(k-1) \quad (1)$$

采取膨胀基数为  $b$  的膨胀卷积之后,网络的感受野  $w$  大小与膨胀因子  $d$  计算公式为

$$w = 1 + \sum_{i=0}^{n-1} (k-1)b^i \quad (2)$$

$$d = b^i \quad (3)$$

可以看出,使用膨胀卷积之后网络感受野随层数的关系,由之前的线性增加变为随膨胀基数指数型增加。

### 2.2 改进的 Skip-TCN Block

为增加长序列预测的准确率,需要提升网络对长期时序关系的学习能力,提高历史信息利用长度。本文提出一种适用于周期性时序数据的一维卷积方

法——跳级卷积连接(图 2)。通过对跨周期数据进行连接,提取周期性特征,并且感受野的增加使模型对历史信息的利用进一步增长。




图 2 跳级卷积连接

Fig. 2 Skip-convolution connections

图 2 中,  $x_i$  为输入时间序列,  $n$  为时间序列的时序周期,  $d$  为膨胀因子即输入序列  $x_i$  的采用间隔, 得到输出  $y_i$  后, 通过从序列起始处填充, 使序列长度保持不变, 并保持因果卷积的特性。跳级卷积连接通过跨越周期的膨胀卷积运算来提取电力负荷数据的长期依赖关系, 并且以较大的周期  $n$  作为膨胀因子  $d$ , 可以使网络的感受更快地增大。

在原始 TCN 网络结构中加入本文提出的跳级卷积连接, 与膨胀因果卷积构成平行支路, 在两次卷积特征提取后, 支路间进行特征融合, 将膨胀因果卷积与跳级卷积提取的特征序列相加, 得到一个改进后的 Skip-TCN 单元。图 3 为改进网络 Skip-TCN 的网络单元, 最左侧支路为两层膨胀因果卷积, 中间支路为两层跳级卷积, 最右侧为残差连接, 可有效加速训练, 防止网络退化。本文采取的并行结构将时序信息的短期因果关系与长期周期信息进行融合, 同时大幅增加原始网络感受野, 可以有效利用更长期的历史信息。

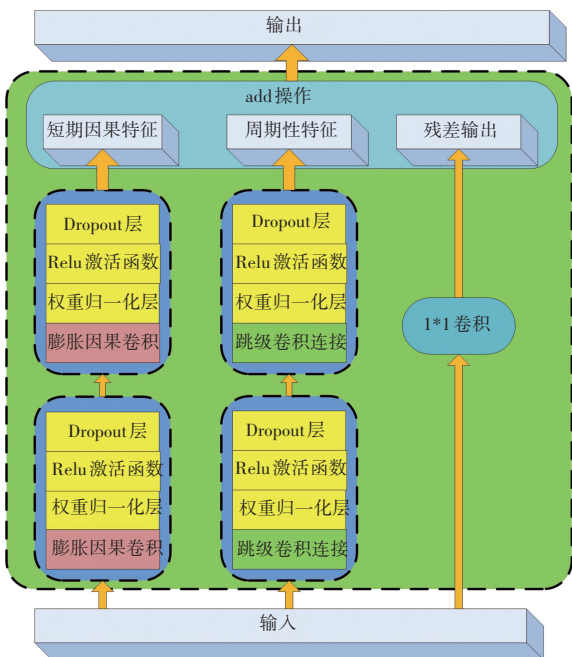


图 3 Skip-TCN block 结构图

Fig. 3 Structure diagram of skip-TCN block

进行第一次信息融合后的网络感受野  $w$  为

$$w = \max\left\{1 + \sum_{i=0}^{n-1} (k-1)b^i, 1 + \sum_{i=0}^1 (k-1)n\right\} \quad (4)$$

为防止间隔采样出现空洞, 一般膨胀基数取 2, 电力负荷序列周期与生活周期及采样粒度相关, 如 1 h 采样粒度的序列周期为 24, 15 min 采样粒度周期为 96。结合式(4)可以看出; 加入跳级卷积通道, 网络感受野堆叠速度得到提升, 对历史信息的利用长度增加。而跳级卷积与膨胀因果卷积的信息融合, 消除了跳级卷积大间隔采样带来的空洞, 且完成了时序信息的短期与长期关系的融合。

### 2.3 STE-TCN 改进网络结构

为了进一步增加预测长度, 本文结合电力负荷数据与生活周期关系紧密的特点(其随季度、日期呈明显变化), 将生活周期信息融入特征。在 Skip-TCN 的基础上加入时间编码网络(Time Encoding Network, TEN), 对输入序列相对应的月、日、周、小时信息进行学习。将输出的特征向量与 Skip-TCN 网络输出向量相拼接, 对输入网络预测部分进行预测, 构成 STE-TCN 模型(图 4)。

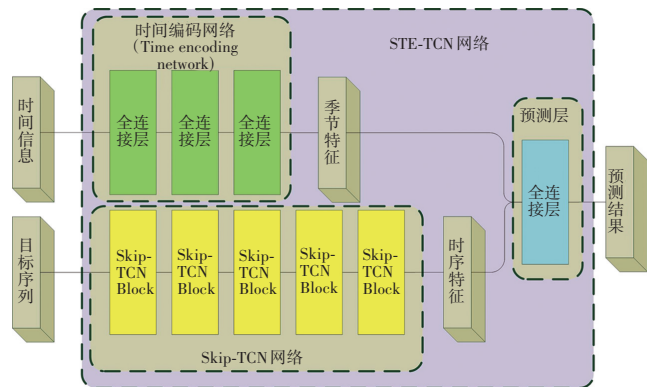


图 4 STE-TCN 模型结构

Fig. 4 STE-TCN model structure

图 4 中, 时间编码网络由 3 层全连接层构成, 输入日期信息, 输出特征向量。预测序列的历史数据输入由 Skip-TCN 单元堆叠在网络中, 输出特征向量与时间编码向量拼接, 送入全连接层进行预测。

## 3 仿真实验与结果分析

### 3.1 数据集及评价指标

实验采用数据集为时序预测公共数据集—Electricity 数据集, 数据集包含 2016 年至 2019 年 321 个客户的每小时用电量, 共 26 304 组数据样本。由于

各组数据分布接近,本次实验将最后一位客户的耗电量设置为目标值,样本数足够本文训练测试。考虑到目标数据规模,为保证测试误差对于泛化误差的近似性,本文按 7:1:2 将数据划分为训练集、测试集、验证集。其数据分布如图 5 所示,图 5 中可以看出:除了周期性外,数据还存在着明显的季节性变化。




图 5 electricity 数据集

Fig. 5 The electricity dataset

为了评估模型预测精度,本文选取均方误差(MSE,其值为  $L_{MSE}$ )和平均绝对误差(Mean Absolute Error, MAE,其值为  $L_{MAE}$ )作为评价标准。MSE 更加关注预测数据偏离更大的误差,而 MAE 更均衡地衡量预测序列总体的误差。结合两者,可以全面对比各算法预测精度。其表达式为

$$L_{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (5)$$

$$L_{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (6)$$

式(5)、式(6)中,  $y_i$  和  $\hat{y}_i$  分别为真实值和预测值,  $n$  为预测数据的长度,  $L_{MSE}$  和  $L_{MAE}$  分别为均方误差和平均绝对误差。

实验环境为 Windows 系统, Intel i5-11400F CPU, EVIDIA RXT3060 显卡,深度学习框架 Pytorch 值。

### 3.2 参数设置与训练过程

TCN 改进部分模型由 Skip-TCN 模块堆叠组成,堆叠的层数增加,网络感受野也会迅速扩大。为了验证增加历史信息有效利用长度能提升网络长序列预测能力,以及确定网络深度,本文对 TCN 不同深度模型对未来 960 个数据点的预测结果进行对比,实验结果如表 1 所示。

表 1 TCN 层数对比实验结果

Table 1 Comparison of experimental results of TCN layer numbers

TCN 模块堆叠层数	$L_{MSE}$	$L_{MAE}$
3 ( $d=1,2,4$ )	0.687	0.675
4 ( $d=1,2,4,8$ )	0.652	0.613
5 ( $d=1,2,4,8,16$ )	0.564	0.560
6 ( $d=1,2,4,8,16,32$ )	<b>0.540</b>	<b>0.534</b>

实验结果表明:层数叠加,TCN 模型感受野逐步扩大的同时,对电力负荷数据的预测精度也不断提高。证明了增加历史信息有效利用长度,可以显著提升模型的预测能力。

层数增加,计算量也会大幅提升,所以本文采用 6 层 TCN 单元堆叠模型与同等规模改进模型为最终实验模型。各模块的通道数为 [40, 80, 160, 320, 640, 1280],原始膨胀系数为 [1, 2, 4, 8, 16, 32],跳越卷积连接跨越长度为自然小时周期 24,卷积核大小均为 3, dropout 值为 0.2。模型选择在大规模数据集上训练,深度网络效果较好的 Adam 算法为网络优化器,回归任务选择 MSE 为损失函数,Adam 学习率并不敏感,适当设置为 0.001,每轮训练结束计算验证集损失,验证集损失两轮训练都未降低时,网络停止训练,取验证集损失最低的训练结果为网络测试权重。

### 3.3 结果分析

为了验证提出的改进方法对长序列预测精度的提升并对比循环结构网络的优势,选取改进效果较好的 LSTMa<sup>[15]</sup>和 LSTnet<sup>[8]</sup>以及原始 TCN 模型与本文改进模型分别对测试集上未来 48 h、168 h、336 h、720 h、960 h 不同序列长度进行预测,对比不同模型不同预测长度的预测精度,并进行分析。

表 2 中 Skip-TCN 为跳级卷积连接的改进 TCN 模型,STE-TCN 为在跳级卷积连接基础上加入时间编码网络的改进模型,总计结果为各模型在数据集上的最优预测精度。由表 2 看出:改进后的 Skip-TCN 模型和 STE-TCN 模型的  $L_{MSE}$  和  $L_{MAE}$  指标相较于 LSTM 改进网络大幅降低,其中 STE-TCN 模型较未改进的 TCN 模型平均下降了 21.9% 和 5.7%。可以发现加入跳级卷积连接和日期编码网络对于预测精度的提升尤为明显。


表 2 Electricity 数据集实验结果  
Table 2 Experimental results of electricity dataset

长度/单位	LSTMa		LSTnet		TCN		Skip-TCN		STE-TCN	
	$L_{MSE}$	$L_{MAE}$	$L_{MSE}$	$L_{MAE}$	$L_{MSE}$	$L_{MAE}$	$L_{MSE}$	$L_{MAE}$	$L_{MSE}$	$L_{MAE}$
48	0.486	0.572	0.369	0.445	0.309	0.393	<b>0.239</b>	<b>0.359</b>	0.265	0.382
168	0.574	0.602	0.394	0.476	0.368	0.436	0.343	<b>0.418</b>	<b>0.323</b>	0.424
336	0.886	0.795	0.419	0.477	0.382	0.442	0.359	<b>0.430</b>	<b>0.341</b>	0.433
720	1.676	1.095	0.556	0.565	0.458	0.498	0.433	0.471	<b>0.366</b>	<b>0.466</b>
960	1.591	1.128	0.605	0.599	0.540	0.534	0.526	0.510	<b>0.359</b>	<b>0.459</b>
总计	0		0		0		4		6	


对比不同预测长度的结果可以发现:预测序列长度增加,LSTM 改进模型的预测精度会迅速大幅下降,而本文改进模型预测精度更高,更适合长序列预测。并且,STE-TCN 的预测精度在预测长度进一步增加后,逐渐高于 Skip-TCN,预测长度越长,精度提升越多。说明在中短期时间跨度内,预测时间跨度的增加、日期信息对于电力负荷预测精度的影响也逐步增加。实验进行预测的时间跨度越大,时间编码网络提供的效果越明显。

为了进一步验证 STE-TCN 不同改进方法对预测能力的提升效果,以及对电力负荷周期性、季节性学习的效果,本文使用原始 TCN、Skip-TCN 模型、STE-TCN 模型对测试集未来 960 h 的电力负荷数据进行预测,并与真实值作图进行对比。


结合图 6 可以看出:原始 TCN 网络可以拟合变化趋势,但是对于变化较大的时刻点,拟合效果较差;Skip-TCN 网络的拟合效果有明显提升,这是因为,原始网络中时序特征的抓取方式使得预测当前值只和当期时刻之前几个时刻的历史值建立关系,加入跳级卷积连接后的 Skip-TCN 网络,对于当前值的预测还和之前几个周期相对应时刻直接建立联系。Skip-TCN 网络对于更长的周期性特征提取能力相较于 TCN 有了大幅度提升,对长序列趋势的拟合效果更好。而电力负荷数据受生活周期的直接影响导致日期编码信息的引入,在 Skip-TCN 的基础上增加了生活周期与季节性对电力负荷的关系(STE-TCN 模型),预测效果进一步提升。图 6 的结果显示:在长序列电力负荷预测中,使用跨越周期的跳越卷积连接更能捕获电力负荷数据中的周期性信息,提升长序列负荷预测精度;日期编码信息的加入则让网络有能力学习到更长的生活周期季节性信息,大幅提升了电力负荷预测的序列长度。



(a) TCN 预测结果



(b) Skip-TCN 预测结果



(c) STE-TCN 预测结果

图 6 各模型预测效果图

Fig. 6 Prediction renderings for each model

## 4 结 论

针对电力负荷这类有着明显时序周期,且与人类生活周期有着直接联系的时间序列,从提高模型本身长序列预测能力出发,针对 TCN 模型做出改进,做到在增加序列长度的基础上保持较高的精准度。根据本文研究可得到以下结论:

增加历史信息的有效利用长度可以提升模型对长序列的预测能力,因为更长的输入序列可以包含更长期的复杂时间模型。

电力负荷与人类生活周期紧密相关,通过充分利用日期信息,网络对电力数据周期性和季节性的拟合能力,提升预测的长度和准确性。

后续研究可以本文所提出 STE-TCN 模型为基础,结合分解复杂时间模式和多尺度输入等其他不同思路,进一步提升模型预测能力。

## 参考文献(References):

- [1] 舒印彪, 陈国平, 贺静波, 等. 构建以新能源为主体的新型电力系统框架研究[J]. 中国工程科学, 2021, 23(6): 61-69.  
SHU Yin-biao, CHEN Guo-ping, HE Jing-bo, et al. Building a new electric power system based on new energy sources[J]. Strategic Study of CAE, 2021, 23(6): 61-69.
- [2] 曹军威, 袁仲达, 明阳阳, 等. 能源互联网大数据分析技术综述[J]. 南方电网技术, 2015, 9(11): 1-12.  
CAO Jun-wei, YUAN Zhong-da, MING Yang-yang, et al. Survey of big data analysis technology for energy Internet[J]. Southern Power System Technology, 2015, 9(11): 1-12.
- [3] ZHOU H, ZHANG S, PENG J, et al. Informer: Beyond efficient transformer for long sequence time-series forecasting[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2021, 35(12): 11106-11115.
- [4] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [5] 胡欣球, 马立新. VMD-LSTM 算法在短期负荷预测中的应用[J]. 电力科学与工程, 2018, 34(6): 9-13.  
HU Xin-qiu, MA Li-xin. Application of VMD-LSTM algorithm in short term load forecasting[J]. Electric Power Science and Engineering, 2018, 34(6): 9-13.
- [6] 郭傅傲, 刘大明, 张振中, 等. 基于特征相关分析修正的 GPSO-LSTM 短期负荷预测[J]. 电测与仪表, 2021, 58(6): 39-48.  
GUO Fu-ao, LIU Da-ming, ZHANG Zhen-zhong, et al. GPSO-LSTM short-term load forecasting based on feature correlation analysis and correction[J]. Electrical Measurement & Instrumentation, 2021, 58(6): 39-48.
- [7] 陈纬楠, 胡志坚, 岳菁鹏, 等. 基于长短期记忆网络和 LightGBM 组合模型的短期负荷预测[J]. 电力系统自动化, 2021, 45(4): 91-97.  
CHEN Wei-nan, HU Zhi-jian, YUE Jing-peng, et al. Short-term load prediction based on combined model of long short-term memory network and light gradient boosting machine[J]. Automation of Electric Power Systems, 2021, 45(4): 91-97.
- [8] LAI G, CHANG W C, YANG Y, et al. Modeling long- and short-term temporal patterns with deep neural networks[C]// Proceedings of the SIGIR' 18: The 41st International ACM SIGIR Conference on Research & Development in Information Retrieval. 2018: 95-104.
- [9] 罗瑞, 刘金培, 陈华友, 等. 基于 LSTM-HFTS-EC 的 PM<sub>2.5</sub> 区间多尺度组合预测研究[J]. 重庆工商大学学报(自然科学版), 2022, 39(2): 59-67.  
LUO Rui, LIU Jin-pei, CHEN Hua-you, et al. Research on PM<sub>2.5</sub> interval multi-scale combination prediction based on LSTM-HFTS-EC[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2022, 39(2): 59-67.
- [10] 李梦, 黄章杰, 徐健晖. 基于深度学习和小波分析的 LSTM-Wavelet 模型股价预测[J]. 重庆工商大学学报(自然科学版), 2023, 40(2): 99-105.  
LI Meng, HUANG Zhang-jie, XU Jian-hui. Stock price prediction with LSTM-wavelet model based on deep learning and wavelet analysis[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2023, 40(2): 99-105.
- [11] 林昕, 朱小栋. 基于 Attention 机制的 LSTM 股价预测模型[J]. 重庆工商大学学报(自然科学版), 2022, 39(2): 75-82.  
LIN Xin, ZHU Xiao-dong. Attention-mechanism-based LSTM model for stock price predicting[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2022, 39(2): 75-82.
- [12] 郭玲, 徐青山, 郑乐. 基于 TCN-GRU 模型的短期负荷预测方法[J]. 电力工程技术, 2021, 40(3): 66-71.  
GUO Ling, XU Qing-shan, ZHENG Le. A forecasting method for short-term load based on TCN-GRU model[J]. Electric Power Engineering Technology, 2021, 40(3): 66-71.
- [13] 孔震, 张华鲁, 岳圣凯, 等. 基于时域卷积网络的多尺度双线性天气预测模型[J]. 图学学报, 2020, 41(5): 764-770.  
KONG Zhen, ZHANG Hua-lu, YUE Sheng-kai, et al. Multi-scale and bilinear models based on temporal convolutional network[J]. Journal of Graphics, 2020, 41(5): 764-770.
- [14] 刘杰, 金勇杰, 田明. 基于 VMD 和 TCN 的多尺度短期电力负荷预测[J]. 电子科技大学学报, 2022, 51(4): 550-557.  
LIU Jie, JIN Yong-jie, TIAN Ming. Multi-scale short-term load forecasting based on VMD and TCN[J]. Journal of University of Electronic Science and Technology of China, 2022, 51(4): 550-557.
- [15] WANG Y, HUANG M, ZHU X, et al. Attention-based LSTM for aspect-level sentiment classification[C]//Proceedings of the Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing. 2016: 606-615.

责任编辑:李翠薇