

耿冠晨, 何宇. 基于 VMD-TCN-Attention 机制的短期电力负荷预测[J]. 智能计算机与应用, 2024, 14(7): 94-99. DOI: 10.20169/j.issn.2095-2163.240714

# 基于 VMD-TCN-Attention 机制的短期电力负荷预测

耿冠晨, 何宇

(贵州大学 电气工程学院, 贵阳 550025)

**摘要:** 为了提升短期电力负荷预测精度, 本文提出一种基于变分模态分解法(VMD)并结合时间卷积网络(TCN)嵌入注意力机制(Attention)的预测框架(VMD-TCN-Attention)。首先, 应用 VMD 分解法分解原始电力负荷序列, 将分解的子序列与气象数据等相关特征组合为预测模型的输入序列; 其次, 选择 TCN 为预测模型并嵌入 Attention 机制; 最后, 通过实例和多种对比预测模型对 VMD-TCN-Attention 预测模型的有效性进行验证。仿真结果表明, 相比较于其他传统预测模型, 本文所提 VMD-TCN-Attention 机制预测模型有着较高的预测精度。

**关键词:** 负荷预测; 时间卷积网络; 注意力机制; 变分模态分解法

中图分类号: TP183

文献标志码: A

文章编号: 2095-2163(2024)07-0094-06

## Short-term power load forecasting based on VMD-TCN-Attention mechanism

GENG Guanchen, HE Yu

(School of Electrical Engineering, Guiyang University, Guiyang 550025, China)

**Abstract:** To improve the accuracy of short-term power load forecasting, a prediction framework is proposed based on Variational Mode Decomposition (VMD) combined with Time Convolutional Network (TCN) embedded with Attention mechanism. Firstly, the VMD decomposition method is applied to decompose the original power load sequence and combine the decomposed subsequences with related features such as meteorological data as the input sequence of the prediction model. Secondly, TCN is chosen as the prediction model and embedded with Attention mechanism to improve the accuracy. The aforementioned input sequence is input into the model to obtain the VMD-TCN-Attention prediction framework. Finally, the effectiveness of the VMD-TCN-Attention prediction model is verified through examples and various comparative prediction models. The simulation results show that the use of VMD decomposition method can improve the prediction accuracy of the model, and compared with other prediction models, the TCN embedded with Attention mechanism prediction model has higher prediction accuracy.

**Key words:** load forecasting; time convolution network; attentional mechanisms; variational mode decomposition

## 0 引言

随着电网规模的日益扩大, 分布式电源和新型微电网大量接入电力系统以及电力需求侧的变化, 使得对电力负荷预测的难度越来越大, 未能准确预测电力负荷会对国民经济和财政产生负面影响<sup>[1-2]</sup>。准确高效的电力负荷预测有助于电网及时对电力分配计划和电力资源进行调节和分配, 同时也是电力市场化改革的要求, 也是保证电力系统稳定、安全、高效运行的前提与保障。因此现代电力系统对负荷预测的要求越来越高, 找到一种更加准确

的负荷预测方法尤为重要。

目前主要分为 3 类方法: 第一类为传统的基于统计模型的预测方法, 主要包括时间序列分析方法和回归预测方法<sup>[3]</sup>。传统的预测方法对于平稳负荷拥有良好的预测性能, 但随着电网的发展, 智能检测设备和电力电子设备的引入使得电网数据越来越大, 分布式电源的接入使得电力负荷呈现出非平稳高频特性。传统的基于统计模型的方法在学习输入和输出变量之间复杂的非线性相互作用方面存在局限性, 因此难以获得精度较高的结果<sup>[4]</sup>。第二类为基于人工智能的预测方法, 可细分为传统机器学习

**基金项目:** 贵州省科技支撑计划(黔科合支撑[2022]一般 014)。

**作者简介:** 耿冠晨(1998-), 男, 硕士研究生, 主要研究方向: 电力负荷预测。

**通讯作者:** 何宇(1978-), 女, 硕士研究生, 副教授, 主要研究方向: 电力系统运行与保护。Email: yhe7@gzu.edu.cn

收稿日期: 2023-05-16

方法和神经网络方法。传统的机器学习方法包括支持向量机(SVM)、决策树及集成随机森林算法(RF)等;神经网络算法有循环神经网络(RNN)及变体长短期记忆神经网络(LSTM)、门控神经网络(GRU)、卷积神经网络(CNN)和深度置信网络(DBN)。随着负荷特征越来越复杂,单一的机器学习方法存在误差率高、计算复杂度高、计算效率低等缺点,很难达到较高的预测精度。第三类为组合预测方法,分为一般组合方法和分解组合方法<sup>[5]</sup>。一般组合方法需要使用多种算法进行预测,将不同算法的预测结果通过分配不同的权重加权组合成最终的预测结果。文献[6-7]基于SVM建立了预测模型,通过对负荷序列进行分解或对SVM进行改进,取得了较好的预测结果;文献[8]通过提取综合相似度小的历史数据训练改进决策树模型,得到了较好的预测结果;文献[9]通过灰色投影对随机森林算法进行改进,构建了预测性能良好的预测模型;文献[10]通过改进PSO优化算法优化RNN网络结点权值参数,提高了RNN网络的预测精度;文献[11-13]分别使用各种分解方法分解原始负荷序列并应用LSTM进行预测,得到了较好的预测结果;文献[14]基于CNN与双向长短期记忆神经网络(BiLSTM)并通过误差修正构建预测模型,并证明了此模型的有效性;文献[15]构建了互补集合经验模态分解法(CEEMD)和模拟退火(SA)优化后的DBN光伏发电出力日期预测模型,并通过算例验证了模型的有效性;文献[16]分别使用Prophet加法模型和长短期记忆(LSTM)网络对负荷进行预测,采用最小二乘法对两种方法取不同的权重组合,得到新的模型。一般组合方法能够获得较高的预测精度,但延展性不足,往往只适用于单一研究对象或系统。文献[17]提出一种经验模式分解(EMD)和堆栈式长短期记忆(SLSTM)的组合预测模型,预测家庭短期负荷并证明了模型在家庭短期负荷预测方面的有效性;文献[18]构建了集合经验模态分解(EEMD)以及门控循环单元神经网络(GRU)和多元线性回归(MLR)组合而成的预测方法,通过MLR对低频分量进行预测,GRU对高频分量进行预测,改进了传统方法因电网负荷随机性较强导致的预测精度不高的问题;文献[19]提出一种基于自适应噪声完备集合经验模态分解(CEEMDAN)和样本熵(SE)的负荷分解方法,通过BP神经网络与Transformer模型进行预测,得到了较好的预测结果。组合预测方法通过将单一方法相结合能够减小预测模型的错误率,

提高预测精度<sup>[20]</sup>。上述文献多采用EMD方法进行负荷序列的分解,容易造成“模态混叠”现象;EEMD和互补集合经验模态分解法(CEEMD)虽然解决了EMD的“模态混叠”现象,但由于主动引入了白噪声,会对结果产生人为影响和误差。

针对电力负荷具有随机性强且传统方法预测精度较低的问题,本文提出一种基于VMD方法对输入负荷序列进行分解,并搭建TCN-Attention预测模型对电力负荷进行预测。首先,通过VMD分解法,减少了分解子序列的时间复杂度,从根本上解决EMD的“模态混叠”现象,并提高了预测模型的训练效率和预测精度;其次,采用TCN预测模型,更好的对时间序列进行处理,具有并行计算的能力,提高模型的训练速度和预测效率;最后,将TCN嵌入Attention机制中,使TCN网络对不同输入序列分配不同权重,进一步提高模型的训练效率和预测精度。选取某地区实际电力负荷数据集对本文提出模型的有效性和准确性进行验证。

## 1 相关理论

### 1.1 变分模态分解法

随着电网的发展,大量分布式能源接入系统和用户侧用电需求的变化,导致电网的负荷特征越来越呈现出高频非平稳的特征,使电力负荷的特征提取越来越难,为了解决负荷特征提取困难的问题,提高预测精度,本文采用VMD将原始负荷序列分解成指定个数负荷子序列,每个负荷子序列拥有各自的中心频率 $\omega$ 和有限带宽的子模态 $U$ 。其分解的主要过程如下:

(1)对子模态进行希尔伯特变换,得到解析信号的单边频谱,式(1):

$$\frac{\delta(t)}{e} + \frac{j}{\pi t} \frac{\delta(t)}{\delta} u_n(t) \quad (1)$$

其中, $\delta(t)$ 为单位脉冲信号; $j$ 为虚数的单位; $u_n(t)$ 为 $n$ 阶模态分解的集合; $n$ 为分解后的第 $n$ 个模态分量。

(2)将频谱变换到乘以指数信号估计的中心频率的基带上,式(2):

$$\frac{\delta(t)}{e} + \frac{j}{\pi t} \frac{\delta(t)}{\delta} u_n(t) \frac{\delta(t)}{\delta} e^{-j\omega_n t} \quad (2)$$

其中, $\omega_n$ 为模态的中心频率。

(3)通过解调信号 $H1$ 高斯平滑估计带宽,可表达其约束变分问题为式(3):

$$\min_{|u_n|, |\omega_n|} = \left\{ \sum_{n=1}^N \left\| \partial_t \frac{\hat{f}(\omega)}{\omega} + \frac{j}{\pi t} u_n(t) \right\|_2^2 \right\} \quad (3)$$

$$\sum_{n=1}^N u_n(t) = f(t)$$

其中,  $N$  为分解的总个数;  $\partial t$  为偏导运算符;  $f(t)$  为未分解主信号。

(4) 通过引入二次惩罚因子  $\alpha$  和 Lagrange 乘子  $\lambda(t)$ , 将其变为非约束性的变分问题进行求解, 式(4):

$$L(|u_n|, |\omega_n|, \lambda) = \alpha \sum_{n=1}^N \left\| \partial_t \frac{\hat{f}(\omega)}{\omega} + \frac{j}{\pi t} u_n(t) \right\|_2^2 + \left\| f(t) - \sum_{n=1}^N u_n(t) \right\|_2^2 + \langle \lambda(t), f(t) - \sum_{n=1}^N u_n(t) \rangle \quad (4)$$

其中:  $\otimes$  为卷积算子。

(5) 通过交替方向乘子法不断迭代更新  $u_n$ ,  $\omega_n$  的值, 见式(5)和式(6):

$$u_n^{k+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{n=1}^N \hat{u}_n(\omega) + \frac{\hat{\lambda}}{2}}{1 + 2\alpha(\omega - \omega_n)^2} \quad (5)$$

$$\omega_n^{k+1} = \frac{\int_0^\infty \omega |\hat{u}_n(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_n(\omega)|^2 d\omega} \quad (6)$$

其中,  $\hat{f}(\omega)$ 、 $\hat{u}_n(\omega)$ 、 $\hat{\lambda}$  分别为  $f(t)$ 、 $u_n(t)$ 、 $\lambda(t)$  的傅里叶变换,  $k$  为迭代次数。

VMD 分解法作为一种非递归信号处理方法, 能将原始信号分解过程转变为变分问题, 相较于 EMD 及其变体分解方法, 对非平稳非线性信号的处理效果更好, 非常适合解决目前电力负荷呈现出的非线性非平稳特性导致的特征难以提取的问题。

## 1.2 时间卷积网络(TCN)

时间卷积网络(TCN)是一种融合扩张卷积、因果卷积(Dilated Causal Convolution, DCC)和残差连接(Residual Connections, RC)的神经网络, 可用于对时间序列进行预测, 网络架构如图1所示。

因果卷积无法看到未来数据, 只能依赖于下层当前及之前时刻的值输出本层当前时刻的值, 即单向结构, 具有因果关系, 是一种严格的时间约束模型, 使用因果卷积不会造成数据泄露。

但因果卷积仍然存在传统神经网络模型的问题, 即受限于卷积核的大小, 很难捕捉较长时间尺度的特征, 因此, TCN 引入扩张卷积对卷积时的输入

间隔采样以获得更大的感受野。扩张卷积运算公式如式(7)所示:

$$F(t) = \sum_{v=0}^{u-1} f(v) X_{t-dv} \quad (7)$$

其中,  $F(t)$  表示在  $X_t$  处的卷积结果;  $d$  为扩张系数;  $u$  为卷积核尺寸;  $X_{t-dv}$  表示对历史负荷数据进行卷积计算;  $f$  表示 TCN 滤波器系数。

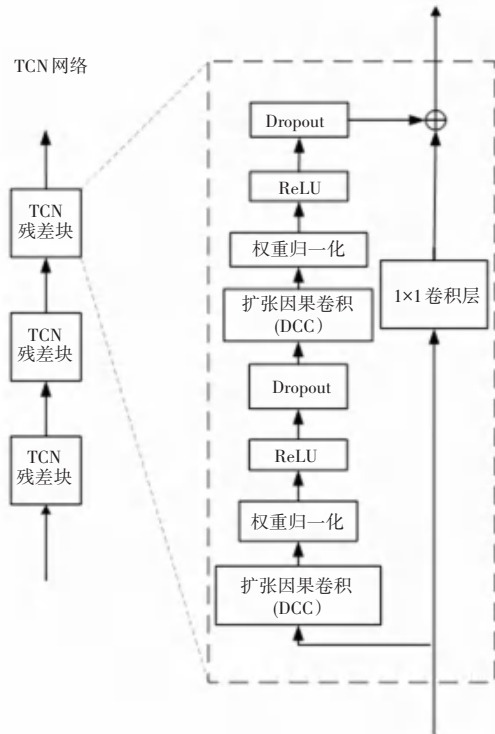


图1 TCN 网络结构

Fig. 1 TCN network structure

TCN 使用残差连接使网络以跨层的方式传递信息, 防止较深的网络结构可能出现的梯度消失问题。

TCN 可以对大规模数据进行并行处理, 通过增加层数, 改变膨胀系数和滤波器的大小扩大其感受野, 提取历史信息的长短更加灵活, 并且一定程度上避免了传统 RNN 网络中梯度消失和梯度爆炸问题, 因此本文选用 TCN 来对负荷数据进行预测。

## 1.3 Attention 机制

Attention 机制是一种能对输入序列自动分配不同权重的模型, 模仿人眼认识事物, 会选择性的关注重要信息而忽视不重要的信息。在 RNN 中, 给定隐藏状态向量  $\mathbf{H} = \{h_1, h_2, \dots, h_{t-1}\}$  并从中提取上下文向量  $\mathbf{v}_t$ ,  $\mathbf{v}_t$  是  $\mathbf{H}$  中每一列  $h_i$  的加权和, 表示与当前时间步长相关的信息,  $\mathbf{v}_t$  进一步与当前状态  $h_t$  相结合, 对负荷进行预测。Attention 的机制如图2所示, 使用式(8)和式(9)来计算上下文向量  $\mathbf{v}_t$ 。

$$\alpha_i = \frac{\exp(f(\mathbf{h}_i, \mathbf{h}_t))}{\sum_{j=1}^{t-1} \exp(f(\mathbf{h}_j, \mathbf{h}_t))} \quad (8)$$

$$\mathbf{v}_t = \sum_{i=1}^{t-1} \alpha_i \mathbf{h}_i \quad (9)$$

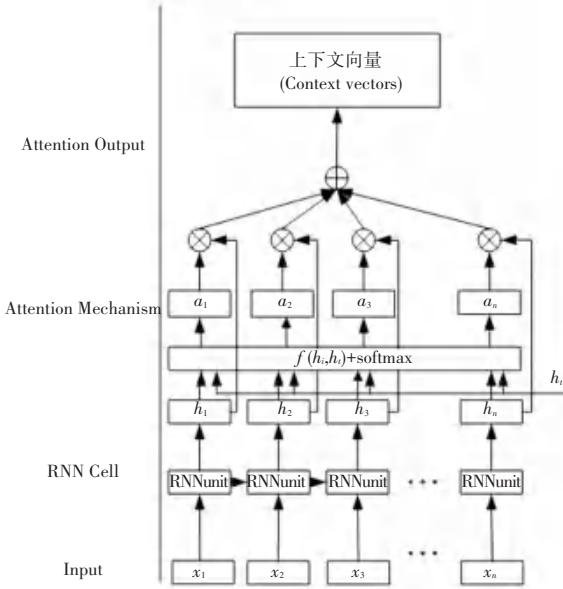


图 2 Attention 机制

Fig. 2 Attention mechanism

$f$  为打分函数, 用来表征先前  $i$  时刻的状态向量  $\mathbf{h}_i$  与当前时刻状态向量  $\mathbf{h}_t$  之间的相关性; 接下来使用 softmax 函数对这些分数进行归一化, 得到各个先前状态向量  $\mathbf{h}_i$  在当前时刻  $\mathbf{h}_t$  上的注意力分布  $\alpha_i$ , 最后根据这些注意力分布有选择性地从输入选择信息, 即注意力分布对输入信息进行加权求和得到上下文向量  $\mathbf{v}_t$ , 其表征模型当前应该关注的内容。注意力机制可以同时考虑全局联系和局部联系, 进一步提高负荷预测的准确性和实时性<sup>[21]</sup>。

### 2 预测模型的构建

首先, 将原始负荷序列应用 VMD 分解法分解为若干子序列, 将各个子序列融合气象数据等特征向量形成新的输入序列;

其次, 因 TCN 具有良好的处理时间负荷序列的能力及并行计算能力, 故在 TCN 的基础上, 将 TCN 嵌入 Attention 机制, 对输入 TCN 模型的历史负荷数据分配不同的权重, 进一步提高 TCN 模型对历史负荷数据特征挖掘能力和并行计算的能力, 提高整体模型的预测精度;

最后, 将各个子序列的预测结果叠加得到最终的负荷预测结果。

因此本文采用 TCN-Attention 预测模型对 VMD

分解的各个子序列进行预测, TCN-Attention 模型结构图如图 3 所示。




图 3 TCN-Attention 预测模型网络结构

Fig. 3 Network structure of TCN-Attention prediction model

本文所提 VMD-TCN-Attention 模型网络结构如图 4 所示。

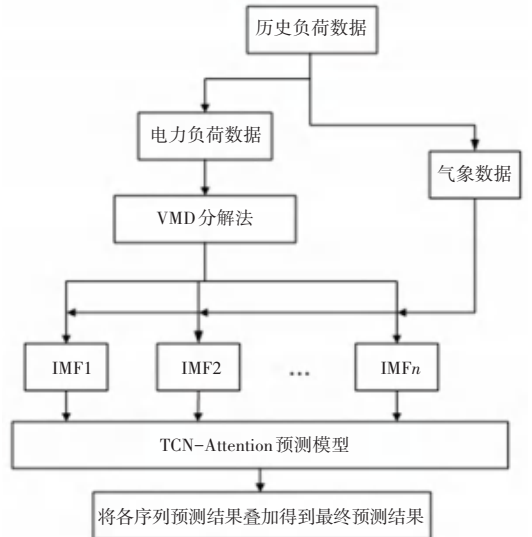


图 4 TCN-Attention 预测模型网络结构

Fig. 4 Network structure of TCN-Attention prediction model

### 3 实验

#### 3.1 算例介绍

为验证 VMD-TCN-Attention 预测模型的可行性, 选取某地区中的电力负荷数据集, 数据采样间隔为 1 h, 共 8 952 条数据, 对所有数据进行预处理。

预测任务: 短期电力负荷预测, 预测步长为 1 h。数据集的划分方式: 2019 年 5 月 1 日 0 点至 2020 年 4 月 30 日 23 点的数据为训练集, 用来训练模型,

2020年5月1日至2020年5月7日的数据为测试集,用来对模型进行测试和评价,训练集有8 784样本,测试集有168样本。

### 3.2 数据预处理及模型评价指标

在本案例中没有异常值和缺失值,故直接对数据进行归一化处理,如式(10)所示:

$$x_{i,s}^{\text{norm}} = \frac{x_{i,s} - x_s^{\text{min}}}{x_s^{\text{max}} - x_s^{\text{min}}} \quad (10)$$

其中,  $x_{i,s}^{\text{norm}}$  表示第  $i$  个样本特征向量第  $s$  个分量归一化后的值;  $x_{i,s}$  为其归一化前的值;  $x_s^{\text{max}}$  和  $x_s^{\text{min}}$  分别表示特征向量第  $s$  个分量的最大值和最小值。

本文使用的评价指标包括均方根误差(Root Mean Squared Error,  $RMSE$ )  $e_{RMSE}$ 、均方误差(Mean-Square Error,  $MSE$ )  $e_{MSE}$ 、平均绝对误差(Mean Absolute Error,  $MAE$ )  $e_{MAE}$ 、平均绝对百分比误差(Mean Absolute Percentage Error,  $MAPE$ )  $e_{MAPE}$ , 计算如式(11)~式(14)所示。上述指标值越小,表明模型预测值与真实值误差越小,模型的预测精度越高。

$$e_{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\bar{y}_i - \hat{y}_i)^2} \quad (11)$$

$$e_{MSE} = \frac{1}{n} \sum_{i=1}^n (\bar{y}_i - \hat{y}_i)^2 \quad (12)$$

$$e_{MAE} = \frac{1}{n} \sum_{i=1}^n |\bar{y}_i - \hat{y}_i| \quad (13)$$

$$e_{MAPE} = \frac{1}{n} \sum_{i=1}^n \frac{|\bar{y}_i - \hat{y}_i|}{\bar{y}_i} \times 100\% \quad (14)$$

其中,  $n$  为样本总数;  $\bar{y}_i$  为真实值;  $\hat{y}_i$  为预测值。

### 3.3 预测模型参数设置

使用VMD对训练集的电力负荷数据进行分解需要设置参数,本文设参数分解序列个数( $K$ )为4,带宽限制( $\alpha$ )为6 000。

VMD分解各子序列曲线如图5所示。

TCN网络中需要设置神经元的个数  $N$  为128个,设置一个全连接层,激活函数为Relu,使用Adam算法优化,训练批次大小设置为64,迭代次数为100。

具体模型参数设置见表1。

表1 TCN-Attention模型参数设置

Table 1 TCN-Attention model parameter settings

神经元个数	激活函数	优化算法	训练批次	迭代次数
128	Relu	Adam	64	100




图5 VMD分解各子序列曲线图

Fig. 5 Curves of each subsequence of VMD decomposition

### 3.4 结果分析

在进行短期电力负荷预测时,对比模型采用长短期记忆神经网络(LSTM)、门控神经网络(GRU)、TCN和TCN-Attention预测模型。本文所提VMD-TCN-Attention模型与对比模型的评价指标见表2,预测结果如图6所示,选取2020年5月1日至2020年5月2日时间段(48 h)的预测结果进行展示,如图7所示。

表2 VMD-TCN-Attention与对比模型评价指标

Table 2 Evaluation indexes of VMD-TCN-Attention and comparison models

模型	$RMSE$	$MSE$	$MAE$	$MAPE$
LSTM	95.190	9 061.206	83.634	0.075
GRU	96.031	9 222.048	82.861	0.074
TCN	65.607	4 304.250	57.252	0.053
TCN-Attention	50.516	2 551.837	39.615	0.036
本文模型	35.561	1 264.575	27.759	0.026

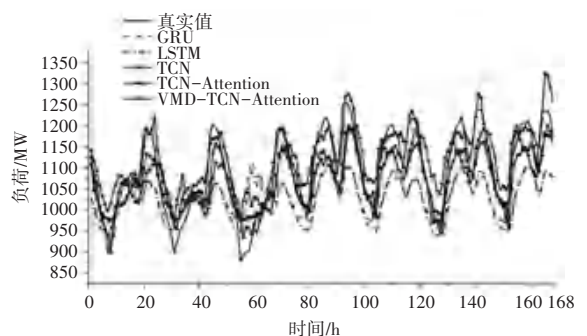


图6 预测结果曲线

Fig. 6 Prediction results curve

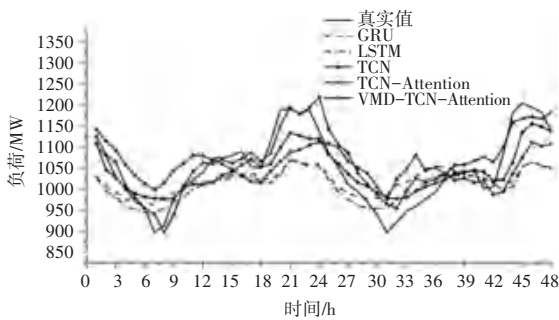


图7 48 h 预测结果曲线

Fig. 7 48 h prediction result curve

从图7中可以看出,5月1号当天的负荷波动较大,TCN相较于LSTM和GRU能够很好的学习现代电力系统非线性非平稳负荷特征并有更高的预测精度,同时TCN嵌入Attention机制后,对于突然的负荷变化也更加接近实际负荷,说明Attention机制对电力负荷影响较大的特征赋予了更高的权重,从而提高了TCN模型的预测精度。本文所提VMD-TCN-Attention预测模型曲线最接近真实值,证明了本文所提方法的有效性同时证明了VMD分解法能够提高模型的特征提取能力,进而有效提高模型的预测精度。

由表2可知,本文所提预测模型在短期电力负荷预测中有更高的预测精度,充分证明了VMD-TCN-Attention预测模型的有效性和准确性。相比于传统的预测模型,本文所提模型对于非线性非平稳的负荷能更有效地提取相关特征并能准确高效地预测,解决了目前对电力负荷特征难以提取和预测精度不高的问题。

## 4 结束语

为了解决现代电力负荷特征难以提取和预测精度不高的问题,本文从负荷序列分解的角度出发,提出了一种基于VMD分解法,TCN网络和Attention机制的VMD-TCN-Attention的短期电力负荷预测模型,并通过算例验证了本文所提预测模型的有效性,并得出以下结论。

(1)使用VMD分解法对负荷进行分解,得到复杂度较小的负荷分量,有利于预测模型对负荷特征的学习和提取,能有效地提高模型的预测精度;

(2)通过实例验证了TCN-Attention预测模型有较高的预测精度,其预测能力的提高取决于VMD分解后的负荷序列的构建、TCN对负荷特征的高效学习和准确的预测能力以及Attention机制对输入序列的权重分配;

通过两者紧密结合,解决了电力负荷特征难以

提取的问题,提高了模型的预测精度,得到了更高精度的预测结果。

## 参考文献

- [1] SMIL V. Perils of long-range energy forecasting: Reflections on looking far ahead [J]. *Technological Forecasting and Social Change*, 2000, 65(3): 251-264.
- [2] YILDIZ B, BILBAO J I, SPROUL A B. A review and analysis of regression and machine learning models on commercial building electricity load forecasting [J]. *Renewable and Sustainable Energy Reviews*, 2017, 73: 1104-1122.
- [3] ZHAO Jing, LIU Xiaojuan. A hybrid method of dynamic cooling and heating load forecasting for office buildings based on artificial intelligence and regression analysis [J]. *Energy and Buildings*, 2018, 174: 293-308.
- [4] IBRAHIM B, RABELO L, GUTIERREZ-FRANCO E, et al. Machine learning for short-term load forecasting in smart grids [J]. *Energies*, 2022, 15(21): 8079.
- [5] 廖旋煊,胡智宏,马莹莹,等. 电力系统短期负荷预测方法综述 [J]. *电力系统保护与控制*, 2011, 39(1): 147-152.
- [6] 吴浩,齐放,张曦,等. 基于小波包分解与最小二乘支持向量机的用户侧净负荷预测 [J]. *现代电力*, 2023, 40(2): 192-200.
- [7] 杨邓,杨俊杰,胡晨阳,等. 基于改进LSSVM的短期电力负荷预测 [J]. *电子测量技术*, 2021, 44(18): 47-53.
- [8] 谷云东,马冬芬,程红超. 基于相似数据选取和改进梯度提升决策树的电力负荷预测 [J]. *电力系统及其自动化学报*, 2019, 31(5): 64-69.
- [9] 吴潇雨,和敬涵,张沛,等. 基于灰色投影改进随机森林算法的电力系统短期负荷预测 [J]. *电力系统自动化*, 2015, 39(12): 50-55.
- [10] 程焕新,黄震. 基于改进PSO优化RNN的短期电力负荷预测模型 [J]. *电子测量技术*, 2019, 42(20): 94-98.
- [11] 魏鹭,茅大钧,韩万里,等. 基于EMD和长短期记忆网络的短期电力负荷预测研究 [J]. *热能动力工程*, 2020, 35(4): 203-209.
- [12] 马梦冬,彭道刚,王丹豪. 基于EEMD-LSTM的区域能源短期负荷预测 [J]. *浙江电力*, 2020, 39(4): 29-35.
- [13] 赵会茹,赵一航,郭森. 基于互补集合经验模态分解和长短期记忆神经网络的短期电力负荷预测 [J]. *中国电力*, 2020, 53(6): 48-55.
- [14] 庄依洁,刘景豪,李盈. 基于CNN-BiLSTM的电力负荷中短期预测 [J]. *数学建模及其应用*, 2022, 11(4): 62-70.
- [15] 杨茂,王凯旋. 基于CEEMD-DBN模型的光伏出力日前区间预测 [J]. *高压电技术*, 2021, 47(4): 1156-1164.
- [16] 彭湃,刘敏. 基于Prophet-LSTM组合模型的短期负荷预测方法 [J]. *电力系统及其自动化学报*, 2021, 33(11): 15-20.
- [17] 刘建华,李锦程,杨龙月,等. 基于EMD-SLSTM的家庭短期负荷预测 [J]. *电力系统保护与控制*, 2019, 47(6): 40-47.
- [18] 邓带雨,李坚,张真源,等. 基于EEMD-GRU-MLR的短期电力负荷预测 [J]. *电网技术*, 2020, 44(2): 593-602.
- [19] HUANG Shichao, ZHANG Jing, HE Ye, et al. Short-term load forecasting based on the CEEMDAN-Sample Entropy-BPNN-transformer [J]. *Energies*, 2022, 15(10): 3659.
- [20] NAQASH A, YAZEED G, MUHAMMAD A, et al. Load forecasting techniques for power system: research challenges and survey [J]. *IEEE Access*, 2022, 10: 71054-71090.
- [21] 王琛,王颖,郑涛,等. 基于ResNet-LSTM网络和注意力机制的综合能源系统多元负荷预测 [J]. *电工技术学报*, 2022, 37(7): 1789-1799.