

基于二次重构分解去噪及双向长短时记忆网络的 极端天气下超短期电力负荷预测

钟燕¹, 王军¹, 宋戈², 吴波², 王涛¹

(1. 西华大学电气与电子信息学院, 四川省 成都市 610039;

2. 国网四川省电力公司成都市供电局, 四川省 成都市 610095)

Ultra-short-term Power Load Prediction Under Extreme Weather Based on Secondary Reconstruction Denoising and BiLSTM

ZHONG Yan¹, WANG Jun¹, SONG Ge², WU Bo², WANG Tao¹

(1. School of Electrical and Electronic Information, Xihua University, Chengdu 610039, Sichuan Province, China;

2. Chengdu Power Supply Bureau, State Grid Sichuan Electric Power Company, Chengdu 610095, Sichuan Province, China)

ABSTRACT: Extreme weather events can cause sudden increases or drops in electrical loads, posing challenges to power grids' stability and power supply capacity. However, the existing ultra-short-term load forecasting methods cannot predict the load characteristics of nonlinear and dynamic changes under extreme weather. To cope with the problem of the reduction of prediction accuracy caused by strong load abruptness and severe fluctuation under extreme weather, this paper proposes an ultra-short-term power load prediction method based on quadratic reconstruction decomposition and denoising and Bidirectional Long Short-Term Memory (BiLSTM) which considering extreme weather. Firstly, the maximum information coefficient was used to select the climate characteristics strongly correlated with load. Then, the features of multiple frequency bands are extracted by the quadratic reconstruction decomposition and denoising method, which reduces the data complexity and provides a cleaner and clearer input sequence for the BiLSTM model to improve the model's training effect and prediction ability. Finally, based on the historical datasets of Belgium, Fujian Province, and Tétouan, the Mean Absolute Percentage Error in different cases decreased to 1.024%, 0.875%, 1.270%, and 1.009%, respectively. Experimental results verify that the proposed method performs well and has broad application prospects in ultra-short-term power load prediction during extreme weather.

KEY WORDS: ultra-short-term load forecasting; extreme weather; quadratic reconstruction decomposition; wavelet packet threshold denoising; bi-directional long-short term memory (BiLSTM)

摘要: 极端天气事件的发生会导致电力负荷产生突增或突降, 对电网的稳定性和供电能力带来挑战。然而, 现有的超短期负荷预测方法对极端天气下非线性和动态变化的负荷特征预测能力有限。为应对极端天气下负荷突变性强及波动剧烈导致的预测精度降低的问题, 提出了一种考虑极端天气的二次重构分解去噪和双向长短时记忆网络(bidirectional long short-term memory, BiLSTM)的超短期电力负荷预测方法。首先, 利用最大信息系数选取能够最大程度反映对负荷影响的气候特征。然后, 通过二次重构分解去噪方法提取到负荷多个频段的特征, 降低数据复杂性, 为 BiLSTM 模型提供更干净和信息量更清晰的输入序列, 从而改善模型的训练效果和预测能力。最后基于比利时、福建省某区域以及得土安市的历史数据集进行算例分析, 不同算例中平均绝对百分比误差分别下降到 1.024%、0.875%、1.270% 和 1.009%, 实验结果验证了所提方法在极端天气发生时的电力负荷超短期预测方面具有较好的预测性能和广阔的应用前景。

关键词: 超短期负荷预测; 极端天气; 二次重构分解; 小波包阈值去噪; 双向长短时记忆网络

DOI: 10.13335/j.1000-3673.pst.2024.0935

0 引言

近年来随着全球气候系统的变化, 极端天气事件的频率和强度增加。当发生极端天气事件时, 如高温或严寒, 电力负荷会呈现激增的变化趋势, 这对超短期电力负荷预测产生了新的挑战^[1]。目前, 电力负荷预测方法主要包括基于传统数学统计的相关方法和基于数据驱动的相关机器学习方法。基于传统数学统计的相关方法包括自回归综合移动平均^[2]的时间序列分析方法和多元线性回归^[3]分析方法和指数平滑法^[4]。统计学的方法虽然模型结构

基金项目: 成都市科技局揭榜挂帅科技项目(2023-JB00-00002-SN)。

Project Supported by a Grant From Chengdu Science and Technology Bureau (No. 2023-JB00-00002-SN).

简单、计算速度快，但是在对波动较大或周期性不够明显的负荷序列进行预测时表现不佳。机器学习方法主要包括支持向量回归^[5]、模糊分析法^[6]、人工神经网络^[7]和深度学习神经网络等。然而，支持向量回归、模糊分析法在应用时主观因素占主导地位，并且当变量数量较多时处理过程更复杂。传统人工神经网络对于多维输入需要通过训练大量数据来避免过拟合，且容易受到局部极小值的影响。

近年来，具有强大的非线性映射和自适应能力的时间卷积网络^[8-9]、Transformer 模型^[10-11]、长短时记忆网络^[12-13]等深度学习算法，被广泛应用于电力负荷预测并具有较好的结果。其中时间卷积网络能够有效提取时序特征，但是对长期依赖关系的建模能力较弱^[14]；Transformer 具有强大的非线性时序依赖关系提取能力，但是在处理长序列时会显著增加计算复杂度，降低预测效率^[15]。由回归神经网络(regression neural network, RNN)^[16]改进而来的长短期记忆网络(long short-term memory, LSTM)^[17]和门控循环单元(gated recurrent unit, GRU)^[18]等通过学习负荷数据的时序特征来提高模型预测能力。LSTM 通过增加门控机制实现时间记忆功能，同时可以防止梯度消失。然而 LSTM 只考虑过去的信息，对未来的信息不能进行综合考虑。GRU 虽然结构更简单，计算速度快，但是在处理长序列时效果逊色于 LSTM。为进一步加强对于负荷序列隐藏信息的利用，双向长短时记忆神经网络被应用于电力负荷预测^[19]。BiLSTM 模型能够捕捉到数据中的时序关系和长期依赖，双向的信息捕捉能力有助于更全面地理解序列中的模式和趋势，从而提高预测的准确性。对上述方法进行组合可以提高预测精度^[20-21]，但是同时会增加计算成本，耗费大量时间训练。

用户复杂的用电行为导致负荷更加难以预测，单纯利用深度学习算法难以学习到负荷的突变性特征，导致预测精度较低，一些学者将其与数据分解算法^[22-23]结合起来用于负荷预测。文献[24]将完全自适应噪声集合经验模态分解(complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN)和 LSTM 结合用于超短期电力负荷预测，对负荷数据分解后再利用 LSTM 对其进行预测，能够相对提升预测精度。基于变分模态分解(variational mode decomposition, VMD)能够较好解决模态混叠现象的优点，文献[25]提出了一种变分模态分解和多模型融合的超短期负荷预测方法，该方法对电、冷、热负荷的预测具有实用性。但是一次分解后的高频分量具有更强的非平稳

性，直接对其进行预测会产生较大的误差。文献[26]对负荷进行一次 CEEMDAN 分解后，根据排列熵值选择出含噪分量并通过小波包分解(wavelet packet decomposition, WPD)进一步分解并预测，这虽然有效提高了预测精度，但较多的子分量会导致计算量大。文献[27]提出了一种基于聚合二次模态分解及 Informer 的短期负荷预测方法，对一次分解后的子序列进行聚合以后再进行二次分解，在降低负荷序列波动性的同时具有更少的分量，能够减少计算量并提升精度，但是并没有考虑到季节性变化和一些异常情况对负荷的影响。针对模态分解方法处理复杂数据会产生噪声残留问题，文献[28]将小波包阈值(wavelet packet threshold, WPT)与模态分解方法相结合用于数据处理。

极端天气条件下，电力负荷具有更强的波动性和突变性，尤其是在出现突然的降温或者热浪期间。现有的预测方法难以捕捉负荷准确的变化规律，从而影响预测精度。在预测时考虑天气等相关因素对负荷的影响能够提高预测精度^[29]。文献[30]利用特征工程对特征变量进行打分筛选出 8 个特征用于负荷预测，然而特征数量过多可能会导致输入冗余信息，增加计算成本。文献[31]将最大信息系数(maximal information coefficient, MIC)方法筛选出的与负荷高度相关的特征与历史负荷一起输入模型，提高了预测精度。但是目前大量文献考虑的是一般天气情况下的负荷预测，鲜少有学者在进行超短期负荷预测时考虑到极端天气的影响。

为充分提取极端天气下天气特征与负荷之间的相关性，本文利用 MIC 方法选取适宜的天气特征集。为克服上述预测方法存在的不足，更好地提取负荷序列的时序特征，提高模型预测精度，将 CEEMDAN、VMD 和小波包阈值去噪(wavelet packet threshold denoising, WPTD)相结合，提出了一种二次重构分解去噪的数据处理方法，并将该方法与 BiLSTM 模型进行结合用于预测极端天气下的超短期电力负荷。首先，通过 CEEMDAN 将预处理后的电力负荷数据进行一次分解；由于波动性较强的高频分量预测难度更大，因此根据各分量的样本熵值将高频固有模态函数(intrinsic mode function, IMF)分量进行重构后再利用 VMD 算法进行二次分解；接着再对二次分解得到的高频子分量进行小波包阈值去噪，从而降低模型的计算复杂度，最后将去噪后的负荷输入 BiLSTM 模型中进行预测，以实现极端天气下超短期负荷的精确预测。基于比利时和中国某地区的真实负荷数据集进行

了实验验证,结果表明,与常见的几种方法相比所提方法能够进一步提升预测精度,并对极端天气下的负荷具有较好的适应性。

1 研究方法

1.1 最大互信息系数

最大互信息系数最早由 D. Reshef 等提出,用于衡量 2 个变量之间的关联程度^[32]。当 MIC 的值为[0,1]时,2 个变量之间的 MIC 值越大表明关联程度越强;当 MIC 值为 0 时,表明变量间相互独立。最大互信息系数的计算步骤详见附录 A。

1.2 完全自适应噪声集合经验模态分解方法

为解决 EMD 中存在的模态混叠问题, TORRES 等^[33]提出了一种改进算法——完全自适应噪声集合经验模态分解。CEEMDAN 通过结合噪声辅助分析和集合平均等技术,可以有效提取出电力负荷序列中不同时间尺度的分量信号,减少伪模态,并有效抑制噪声对分析结果的影响,从而降低原始负荷序列的复杂性和非平稳性。CEEMDAN 的分解步骤详见附录 A。

1.3 样本熵

样本熵(sample entropy, SE)是一种通过度量信号中产生新模式的概率的大小来衡量时间序列复杂性的方法,新模式产生的概率越大,时间序列的复杂性就越大^[34]。本文选择采用样本熵来衡量经过分解后得到的本征模态分量的复杂程度,并划分出高频和低频分量。样本熵的计算步骤详见附录 A。

1.4 变分模态分解算法

VMD 是一种自适应、完全非递归的模态变分和信号处理的方法。该方法通过确定模态分解的个

数以构造变分约束问题,以及不断对每种模态的最佳中心频率和有限带宽进行寻优,实现模态分量的有效分离、信号的频域划分,进而得到给定信号的有效分解成分,同时获得变分问题的最优解^[35]。

VMD 算法的分解步骤详见附录 A。

1.5 小波包阈值去噪

小波包阈值去噪(WPTD)是一种基于小波包变换的信号去噪方法。该方法将小波系数分为噪声和信号 2 部分,从而实现信号的去噪。通过选择合适的阈值,可有效保留信号的瞬态和细节部分,并消除随机噪声的影响,提高信号的精确度和可靠性^[36]。WPTD 的基本流程详见附录 A。

1.6 双向长短时记忆网络

BiLSTM 通过在输入序列的 2 个方向上分别运行 2 个独立的 LSTM 网络来增强建模能力,能够同时考虑时间序列数据不同时间尺度的趋势和周期性,例如短期波动和长期趋势,从而更好地捕捉数据的多样性和复杂性^[37]。其中 LSTM 的计算过程详见附录 A。BiLSTM 网络的计算过程如式(1)所示。

$$\begin{cases} \overleftarrow{h}_t = \text{LSTM}(x_t, \overleftarrow{h}_{t-1}) \\ \overrightarrow{h}_t = \text{LSTM}(x_t, \overrightarrow{h}_{t-1}) \\ y_t = W_t \overleftarrow{h}_t + V_t \overrightarrow{h}_t + b_y \end{cases} \quad (1)$$

式中: \overleftarrow{h}_t 为前向 LSTM 输出; \overrightarrow{h}_t 为 LSTM 输出; W_t 和 V_t 分别为各隐藏层输出权重; LSTM(\bullet) 则表示 LSTM 的计算过程。

BiLSTM 的模型结构如图 1 所示。将处理后的电力负荷数据、大气温度、露点温度、相对湿度以及平均风速作为特征输入数据集。通过 BiLSTM 模型对时序特征进行学习,并输出负荷预测结果。

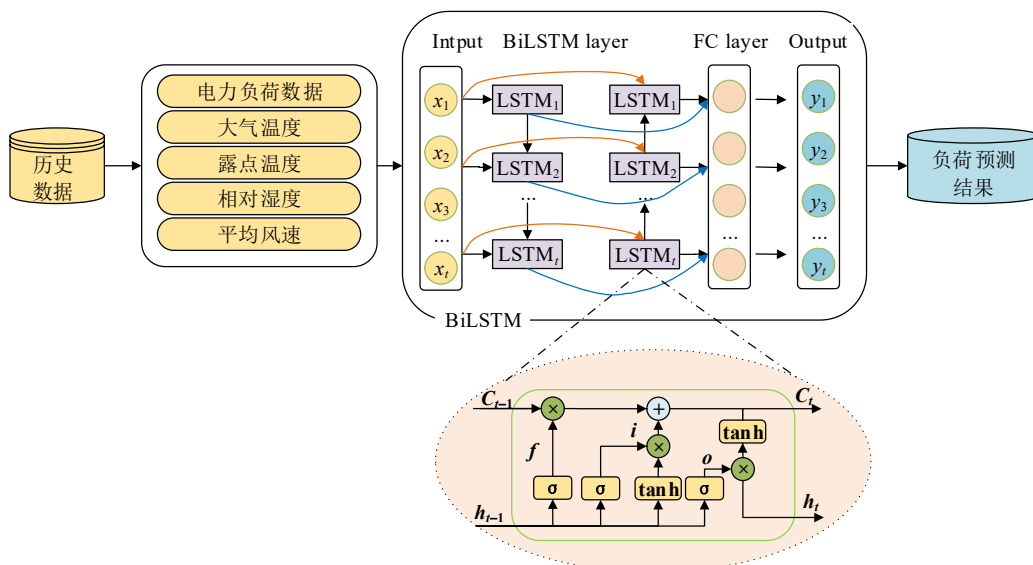


图 1 BiLSTM 模型结构
Fig. 1 BiLSTM model structure

BiLSTM 模型包括输入层、BiLSTM 层、全连接层和输出层，其中 BiLSTM 层用于获取前向信息和反向信息，而全连接层用于拼接 2 层 LSTM 的输出，从而获得最终输出。

2 基于 CSVMD-WPTD-BiLSTM 预测模型的建立

2.1 二次重构分解去噪方法

在极端天气情况下，电力负荷在短时间内会发生骤增或突降，呈现出更为复杂的波动性和非平稳性。这使得现有预测方法对负荷序列进行特征提取时更加困难，故本文将 CEEMDAN、VMD 和 SE 结合用于负荷序列二次重构分解，实现对各种周期和趋势成分的精细化提取，为后续模型分析负荷变化规律降低复杂度，从而获得更好的负荷预测精度。

本文首先通过 CEEMDAN 方法将原始电力负荷数据分解为一组本征模态分量(C_{EIMF1} - C_{EIMFn})以及残余项 res ，然后分别计算每个分量的样本熵值，将样本熵值高于 0.5 的高频分量进行重构，接着对重构后的高频分量进行再次分解，得到一组 VMD 分解分量(V_{IMF1} - V_{IMFn})。由附录图 A1 可以看出，经过二次重构分解后的本征模态分量的样本熵值均降低到了 1 以下。证明该方法能够在处理复杂信号、提取关键特征方面实现更好的性能。

为进一步去除各分量中的噪声，降低复杂程度，将上述的二次重构分解方法与小波包阈值去噪算法相结合用于本文的数据去噪处理，将其简称为 CSVMD-WPTD 方法。二次重构分解联合小波包阈值去噪的流程如图 2 所示，主要包括以下步骤。

1) 二次分解：使用 CEEMDAN-SE-VMD 将原始信号分解为一系列本征模态函数。

2) 样本熵值计算：对每个模态分量进行样本熵分析，计算不同尺度下的样本熵值，获取信号在不同时间尺度上的信息量。

3) 小波包阈值去噪：根据样本熵的结果，对模态分量进行阈值处理。根据样本熵的大小设置出合适的阈值，保留样本熵值较低的分量，而将样本熵值较高的分量进行小波包变换，对变换后的系数进行阈值处理，通过设置适当的阈值来滤除噪声成分，保留主要的信号特征。

4) 信号重构：将去噪后的分量和原本保留的分量进行重构，获得最终去噪后的信号。

该方法结合了 CEEMDAN 的自适应噪声提取能力、VMD 的信号增强能力和小波包阈值处理的

噪声滤除能力。该方法具有更精细的负荷特征提取能力，并能实现对负荷变化的本质和机制的深入理解，通过对原始负荷序列中的噪声和干扰进行去除能够获得更干净的负荷成分，进而提高对未来负荷变化的预测能力和准确度。

本文在进行历史电力负荷数据分解去噪处理时，选择的阈值为 $SE=0.5$ ，因此对二次重构分解得到的分量进行小波包阈值去噪时一般是对 VMD 分解得到的分量进行去噪，而 CEEMDAN 得到的低频分量无需进行再次处理，最后通过将所有的分量重构得到去噪后的电力负荷数据。图 3 明显看出小波包阈值去噪能够显著降低序列的非平稳性。

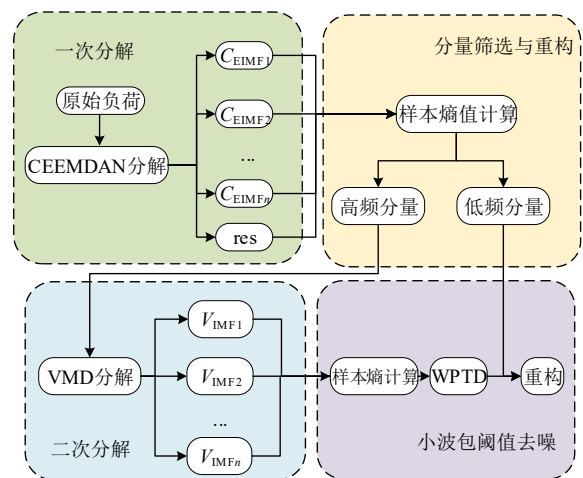


图 2 二次重构分解联合小波包阈值去噪流程

Fig. 2 Flowchart of secondary reconstruction decomposition combined with wavelet packet threshold denoising

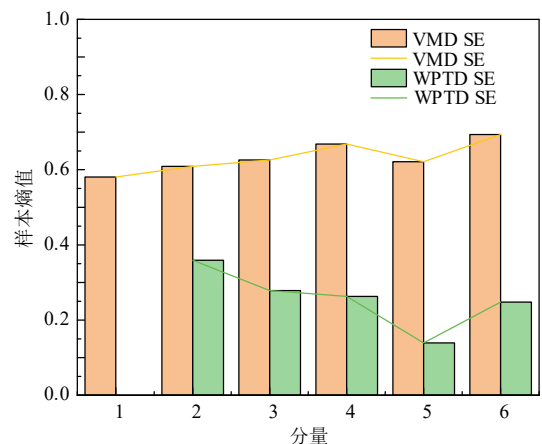


图 3 去噪前后样本熵值对比

Fig. 3 Comparison of the entropy value of noise samples before and after denoising

2.2 基于 CSVMD-WPTD-BiLSTM 的预测模型

由于极端天气下电力负荷序列随天气产生不寻常的波动，这些波动增大了预测的难度，因此为减弱序列的波动性和非平稳性，有效提取负荷序列的时序特征，本文通过将二次重构分解去噪的方法

与深度学习模型相结合,构建了基于二次重构分解去噪和 BiLSTM 的极端天气下超短期负荷预测模型,预测模型框架如图4所示。首先利用最大互信息系数筛选出高度相关的天气特征作为输入特征,避免将冗余信息引入模型。之后对负荷序列进行二次重构分解去噪处理:利用 CEEMDAN 对负荷进行一次分解,将原始序列分解为复杂度不同的子序列,初步降低序列波动性;由于复杂度较高的序列预测难度更大,因此基于样本熵对高频子序列进行重构后再进行 VMD 二次分解,以进一步降低序列波动性;使用 WPTD 对二次重构分解后的序列进一步去噪,以获得更干净的负荷成分,提取到更精确的时序特征。考虑到 BiLSTM 能够提取序列数据的双向时序特征以及捕捉序列变化的能力,因此构建 BiLSTM 模型对输入数据进行预测,从而获得最终的负荷预测结果。

2.3 模型评价指标

本文选取均方根误差 E_{RMSE} 、平均绝对误差 E_{MAE} 、平均绝对百分比误差 E_{MAPE} 、决定系数 R^2 、

和预测精度指标 R_{PA} 来评价模型的预测结果。这些度量指标的定义如下。

E_{RMSE} 又称标准误差,是预测值与实际值之差的平方和与预测次数之比的平方根,取值范围为[0, 1)。 E_{RMSE} 值越大,误差越大,反之亦然。 E_{RMSE} 的计算过程如下:

$$E_{RMSE} = \sqrt{\frac{1}{N} \sum_{n=1}^N [p_{rei} - y_i]^2} \quad (2)$$

式中: p_{re} 表示最终预测结果; y 表示原始数据; p_{rei} 和 y_i 表示给定时刻数据集的值。

E_{MAE} 可以反映每个数据相对于真实数据的绝对值误差,是目前应用最广泛的性能指标。在[0, +1]范围内, E_{MAE} 越大,误差越大,反之越小。 E_{MAE} 计算过程如下:

$$E_{MAE} = \frac{1}{N} \sum_{i=1}^N |p_{rei} - y_i| \quad (3)$$

E_{MAPE} 可以将模型的预测效果清晰地表示为数据的百分比,其取值范围为[0, 1]。 E_{MAPE} 值越小,

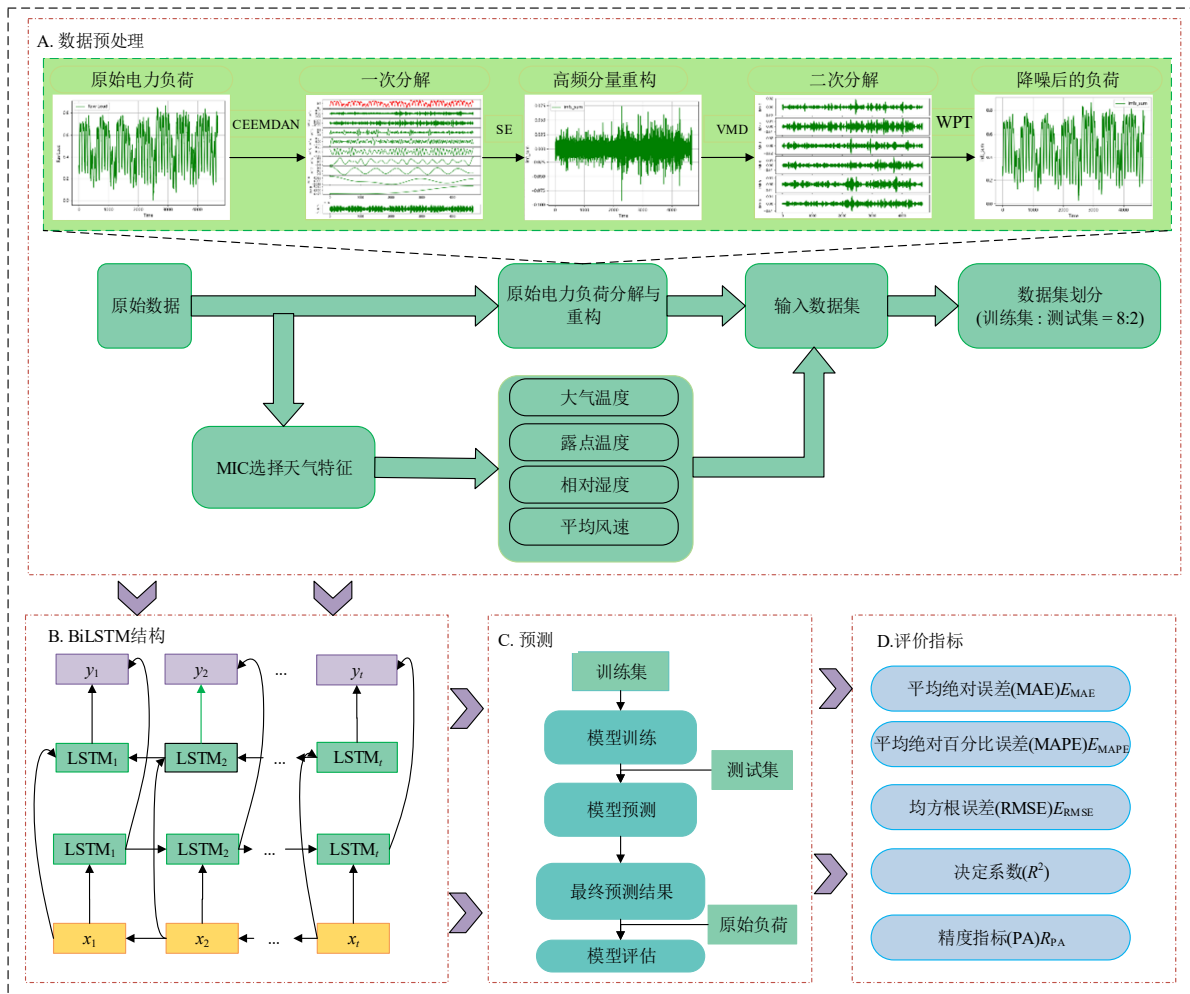


图4 基于二次重构分解去噪的超短期负荷预测框架

Fig. 4 An ultra-short-term load prediction framework based on quadratic reconstruction decomposition combined with wavelet packet threshold denoising

模型预测精度越高；若 E_{MAPE} 为 0，则该模型为完美模型，其计算过程如下：

$$E_{MAPE} = \frac{100\%}{N} \sum_{i=1}^N \left| \frac{p_{rci} - y_i}{y_i} \right| \quad (4)$$

R^2 用来表示模型的预测拟合度。根据 R-Squared 的取值，来判断模型的好坏，其取值范围为[0,1]。

$$R^2 = 1 - \frac{\sum_{i=1}^N |p_{rci} - y_i|^2}{\sum_{i=1}^N |p_{rci} - \bar{y}|^2} \quad (5)$$

R_{PA} 值越大表明预测值越接近真实值，预测精度越好。

$$R_{PA} = \frac{100\%}{N} \sum_{i=1}^N [1 - | \frac{p_{rci} - y_i}{y_i} |] \quad (6)$$

式中： N 表示数据长度； \bar{p}_{rci} 表示预测数据集的平均值。

3 算例分析

为验证本文提出的方法应对极端天气发生时的有效性与优越性，选取了比利时 2019 年发生极端高温和 2021 年发生极端低温时的历史数据，中国福建省泉州市 2017 年发生极端高温以及摩洛哥得土安市的数据集进行实验验证。选取不同分解方法和不同模型与本文提出的方法进行对比，本文提出的方法在有效性与优越性得到了较好的验证。

本文实验硬件平台为 Intel(R) Core(TM) i5-1035G7 CPU，软件平台为 Python3.7 环境，使用 TensorFlow2.4.0 CPU 版本作为实验框架。

3.1 数据处理

3.1.1 天气特征选择

近些年，极端天气频繁发生，造成电力负荷激增，扰乱电力系统发电节奏，导致电力供需不平衡。例如，2020 年湖南江西等地发生低温寒潮时供电不足导致缺电，2022 年，四川省由于异常高温和干旱等极端天气造成了电力电量双缺的情况。由此可以看出，天气特征与电力负荷之间存在着密切的相关性，尤其是发生高温或者严寒天气时会导致空调、采暖等电气设备用电负荷明显增加，这些情况体现在综合负荷上时就会出现负荷突增和非线性更加突出的特点。因此正确选择天气特征输入预测模型在一定程度上可以提高负荷预测的准确性。

本文采用最大信息系数来衡量不同情况下天气特征与电力负荷之间的关联程度，结果如表 1 所示。其中在一般天气情况和极端高温时大气压强的系数最高，大气温度和相对湿度影响次之，特别是

在发生极端高温时可以看出，天气特征与电力负荷的相关性会更强一些。因此在这 2 种情况下选择关联程度较高的气温、大气压强、相对湿度作为影响特征输入预测模型。而当发生极端低温时，关联度较强的为气温、露点温度和大气压强，因此选择这 3 种特征作为输入特征集。

影响特征	最大信息系数		
	一般天气	极端高温	极端低温
大气温度	0.58	0.61	0.53
露点温度	0.38	0.37	0.52
大气压强	0.56	0.76	0.54
相对湿度	0.47	0.60	0.33
平均风速	0.31	0.43	0.23

3.1.2 数据分解重构去噪

以比利时 2019 年 6 月 1 日至 7 月 31 日的 5855 条数据为例进行二次重构分解并去噪处理。首先对负荷数据进行 CEEMDAN 分解，分解结果如图 5 所示。




图 5 CEEMDAN 分解结果

Fig. 5 CEEMDAN decomposition results

通过计算出 CEEMDAN 各 IMF 分量的样本熵值，从而区分出高频分量和低频分量。样本熵值计算结果如表 2 所示。由表 2 可知， C_{EIMF1} 和 C_{EIMF2} 分量的样本熵值远大于其他分量，因此将 C_{EIMF1} 和 C_{EIMF2} 分量进行重构作为高频分量，其余为低频分量。

将重构得到的高频分量进行 VMD 分解，如附录图 B1 所示。其中 VMD 的分解个数 k 为 6， α 为 7000，得到 VMD 分量，并对样本熵值高于 0.5 的分量进行小波包阈值去噪处理，结果如表 3 所示。可以看出：经过去噪处理后，分量的样本熵值明显

表 2 CEEMDAN 分量样本熵值
Table 2 Entropy values of CEEMDAN component samples

C_{EIMF_s}	C_{EIMF1}	C_{EIMF2}	C_{EIMF3}	C_{EIMF4}	C_{EIMF5}	C_{EIMF6}	C_{EIMF7}	C_{EIMF8}	C_{EIMF9}
SE	1.64	1.50	0.61	0.52	0.42	0.08	0.05	0.01	0.002

表 3 VMD 分量样本熵值及去噪后样本熵值
Table 3 Entropy of VMD component samples and the entropy of denoised samples

IMF_s	IMF1	IMF2	IMF3	IMF4	IMF5	IMF6
VMD-SE	0.581	0.609	0.626	0.668	0.621	0.694
WPTD-SE	0.359	0.275	0.263	0.139	0.248	

降低，数据非平稳性得到改善。

最后将所有的分量进行重构，得到去噪后的电力负荷数据。去噪后的数据与原始数据进行对比，拟合程度 R^2 为 0.997。由附录图 B2 可以看出：去除噪声后，局部特征得到保留，非平稳性得到了改善。

3.2 算例 1 实验验证

为了验证本文方法在发生极端天气时对于超短期电力负荷预测的有效性，分别选取比利时 2019 年 6 月至 7 月和 2021 年 3 月至 4 月的历史真实数据进行极端天气下的负荷预测实验。这些数据采样频率同样为 15min，按照 8:2 的比例进行训练集与测试集的划分。将训练集用于模型的训练，将测试集用于评价模型预测性能并进行对比。

3.2.1 极端高温情况

根据历史天气记载，2019 年 7 月比利时发生了极端高温热浪天气，最高气温高于 40℃，打破历史纪录。因此选取了比利时 2019 年 6 月 1 日至 7 月 30 日的历史数据进行极端高温预测实验。

1) 不同分解方法对比。

为验证本文的二次分解联合小波包阈值去噪方法的有效性，将其与不分解、CEEMDAN 一次分解、VMD 一次分解和 VMD-CEEMDAN 二次分解方法进行对比，结果如附录图 B3 所示。

为比较本文方法的性能，附录表 B1 给出了在极端高温天气下本文方法负荷预测结果和其他几种方法预测结果的误差对比。对表 B1 分析可知，在针对极端高温下的超短期负荷预测时，由于对序列进行一次分解后会产生高频随机分量，对其进行预测时会增加难度；并且，一般的二次分解是对一次分解的残差进行二次分解，使得一次分解的高频分量仍然存在。因此，CEEMDAN-BiLSTM、VMD-BiLSTM 和 VMD-CEEMDAN-BiLSTM 等预测方法在应对极端天气下突变性强和非线性明显的负荷数据时，不能达到理想的效果，导致这些方法在极端高温下的超短期负荷预测时误差大。而相较于直

接预测，本文方法的 E_{RMSE} 下降了 4.83%， E_{MAE} 下降了 7.20%， E_{MAPE} 下降了 6.82%，因此本文所提出的方法在进行极端高温下预测时仍具有比其他模型更好的预测精度。

2) 不同模型对比。

将本文方法与常见的效果较好的 CNN-BiGRU、TCN-BiLSTM 和 VMD-TCN-Attention 几种模型进行对比，对比结果如附录图 B4 和表 B2 所示。

由图 B4 明显看出，在负荷曲线波峰处，本文方法的预测曲线能够较好地跟随实际负荷曲线，其他模型的预测曲线跟随效果次之，其中 VMD-TCN-Attention 的效果最差。表 B2 中，本文方法相对于 CNN-BiGRU、TCN-BiLSTM 和 VMD-TCN-Attention 的模型拟合系数 R^2 均有所提升；而 E_{MAPE} 分别降低了 16.82%、7.50% 和 6.23%。这是由于负荷曲线在波峰波谷处的波动性最强，时序特征也最为复杂，传统的预测方法学习效果比较弱，而本文方法可以弥补这一不足。

3.2.2 极端低温情况

2021 年上半年比利时极端天气频繁发生，特别是 2021 年 4 月 7 日的罕见降雪，气温低至零下 3℃。2021 年 4 月平均气温 2.5℃，创下了 1986 年以来的最低纪录。因此选取了比利时 2021 年 3 月 1 日至 4 月 30 日的历史数据进行极端低温预测实验。

1) 不同分解方法对比。

预测结果如附录图 B5 所示，误差对比如附录表 B3 所示。表 B3 列出了所提方法与对比方法在极端低温天气下的负荷预测结果的误差对比。由表中数据可知，与直接预测相比，CEEMDAN-BiLSTM 模型能够提高预测精度，然而 VMD-BiLSTM 和 VMD-CEEMDAN-BiLSTM 2 种模型降低了预测精度。本文方法与 CEEMDAN-BiLSTM 相比， E_{RMSE} 下降了 1.67%， E_{MAE} 下降了 3.41%， E_{MAPE} 下降了 3.31%。由此可以得出，本文方法在进行极端低温下的超短期负荷预测时具有一定的优越性。

2) 不同模型对比。

预测结果对比如附录图 B6 所示，误差对比如附录表 B4 所示。其中与 CNN-BiGRU、TCN-BiLSTM 和 VMD-TCN-Attention 相比，本文方法的 E_{MAPE} 分别降低了 6.50%，15.47%，5.67%。由图 B6 可知，极端低温情况下，超短期负荷曲线具有

更大的波动性，可以看出，本文方法的预测曲线与实际曲线的拟合度最好，这是因为通过对序列的波动性和非平稳性进行削弱后模型能够更好地学习序列的时序特征，从而更好地预测出未来负荷的变化趋势，有效提高预测精度。

3.3 算例 2 实验验证

为进一步验证模型对不同数据集的适应性以及在一般天气情况下负荷预测也具有优越性，将本文方法与对比模型在福建省泉州市 2017 年 9 月的数据集和摩洛哥得土安市历史数据集上进行预测实验。由于在算例 1 中发现除本文分解方法以外，效果较好的方法为 CEEMDAN-BiLSTM，因此该部分选择 CEEMDAN-BiLSTM、CNN-BiGRU、TCN-BiLSTM 和 VMD-TCN-Attention 作为对比方法进行实验验证。其中泉州市数据集的模型预测结果如附录图 B7 所示，预测误差对比结果如附录表 B5 所示。从图 B7 和表 B5 可知，相较于对比方法，本文方法的预测误差明显下降，其中 E_{RMSE} 、 E_{MAE} 和 E_{MAPE} 平均下降 10.33%、19.09% 和 24.09%。可以看出，本文方法在应对极端天气下负荷数据的预测时能够明显提高预测精度。并且本文方法的 R^2 指标达到 0.992，均高于其他方法，说明本文方法在提取负荷时序特征时较优于其他方法，对真实负荷的非线性拟合能力更强。

摩洛哥得土安市历史数据集的预测结果如附录图 B8 所示。预测误差对比结果如附录表 B6 所示。由图 B8 和表 B6 可知，对一般天气情况下的超短期负荷预测，本文方法相较于 CEEMDAN-BiLSTM、CNN-BiGRU、TCN-BiLSTM、和 VMD-TCN-Attention 等方法预测精度最好。其中 E_{MAPE} 值比其他模型平均下降了 27.46%。

从算例 2 中的实验结果可知，本文方法相较于其他对比方法，均呈现出更优的预测效果。本文方法对于 2 个数据集也具有较好的适用性，并且在对一般天气下的超短期负荷进行预测时，本文方法同样具有有效性。

4 结论

本文构建了一种二次重构分解去噪结合 BiLSTM 的预测方法，用于预测极端天气下的超短期电力负荷。该模型通过对数据进行二次重构分解去噪实现对负荷序列深层次特征的提取，并通过 BiLSTM 进行预测。主要结论如下：

1) 通过 MIC 对发生极端天气时的影响特征进行筛选，能够进一步挖掘气候因素与负荷之间的耦

合关系，实现预测不同时刻负荷预测的对应特征集，从而有效提升模型预测精度。

2) 本文通过对数据进行二次重构分解去噪实现了对负荷数据的潜在时序特征的提取，通过对比分析，该方法能够保留有效信息的同时降低时间序列的波动性，为后续模型预测减少计算量。

3) 将去噪后的负荷数据与对应的特征集作为 BiLSTM 模型的输入，负荷数据的时序性和复杂的非线性关系能够被有效提取，从而获得比其他模型更好的预测精度。

本文提出的数据处理方法主要是为了提升模型输入数据的质量，减少信息冗余和去除无效信息，提高模型的学习效率，减少模型的计算量，节约计算资源。在后续的研究中可以通过将本文的数据处理方法与其他更高效的模型进行结合，从而提升模型预测性能。

附录见本刊网络版 (<http://www.dwjs.com.cn/CN/1000-3673/current.shtml>)。

参考文献

- [1] 韩富佳, 王晓辉, 乔骥, 等. 基于人工智能技术的新型电力系统负荷预测研究综述[J]. 中国电机工程学报, 2023, 43(22): 8569-8591. HAN Fujia, WANG Xiaohui, QIAO Ji, et al. Review on artificial intelligence based load forecasting research for the new-type power system[J]. Proceedings of the CSEE, 2023, 43(22): 8569-8591(in Chinese).
- [2] ZHANG Jinliang, WEI Yiming, LI Dezhi, et al. Short term electricity load forecasting using a hybrid model[J]. Energy, 2018, 158: 774-781.
- [3] SELVI M V, MISHRA S. Investigation of performance of electric load power forecasting in multiple time horizons with new architecture realized in multivariate linear regression and feed-forward neural network techniques[J]. IEEE Transactions on Industry Applications, 2020, 56(5): 5603-5612.
- [4] SMYL S. A hybrid method of exponential smoothing and recurrent neural networks for time series forecasting[J]. International Journal of Forecasting, 2020, 36(1): 75-85.
- [5] PENG Chong, CHE Zhongyuan, LIAO T W, et al. Prediction using multi-objective slime mould algorithm optimized support vector regression model[J]. Applied Soft Computing, 2023, 145: 110580.
- [6] SADA EI H J, DE LIMA E SILVA P C, GUIMARÃES F G, et al. Short-term load forecasting by using a combined method of convolutional neural networks and fuzzy time series[J]. Energy, 2019, 175: 365-377.
- [7] ZHANG Guoqiang, PATUWO B E, HU M Y. Forecasting with artificial neural networks: the state of the art[J]. International Journal of Forecasting, 1998, 14(1): 35-62.
- [8] 庞昊, 高金峰, 杜耀恒. 基于时间卷积网络分位数回归的短期负荷概率密度预测方法[J]. 电网技术, 2020, 44(4): 1343-1349. PANG Hao, GAO Jinfeng, DU Yaoheng. A short-term load probability density prediction based on quantile regression of time convolution network[J]. Power System Technology, 2020, 44(4): 1343-1349(in Chinese).
- [9] WANG Yuanyuan, CHEN Jun, CHEN Xiaoqiao, et al. Short-term load

- forecasting for industrial customers based on TCN-LightGBM[J]. *IEEE Transactions on Power Systems*, 2021, 36(3): 1984-1997.
- [10] 骆钊, 吴谕侯, 朱家祥, 等. 基于多尺度时间序列块自编码 Transformer 神经网络模型的风电超短期功率预测[J]. *电网技术*, 2023, 47(9): 3527-3536.
- LUO Zhao, WU Yuhou, ZHU Jiexiang, et al. Wind power forecasting based on multi-scale time series block auto-encoder transformer neural network model[J]. *Power System Technology*, 2023, 47(9): 3527-3536(in Chinese).
- [11] 李练兵, 高国强, 吴伟强, 等. 考虑特征重组与改进 Transformer 的风电功率短期日前预测方法[J]. *电网技术*, 2024, 48(4): 1466-1476.
- LI Lianbing, GAO Guoqiang, WU Weiqiang, et al. Short-term day-ahead wind power prediction considering feature recombination and improved transformer[J]. *Power System Technology*, 2024, 48(4): 1466-1476(in Chinese).
- [12] 陈振宇, 刘金波, 李晨, 等. 基于 LSTM 与 XGBoost 组合模型的超短期电力负荷预测[J]. *电网技术*, 2020, 44(2): 614-620.
- CHEN Zhenyu, LIU Jinbo, LI Chen, et al. Ultra short-term power load forecasting based on combined LSTM-XGBoost model[J]. *Power System Technology*, 2020, 44(2): 614-620(in Chinese).
- [13] 刘亚辉, 赵倩. 基于聚类经验模态分解的 CNN-LSTM 超短期电力负荷预测[J]. *电网技术*, 2021, 45(11): 4444-4451.
- LIU Yahui, ZHAO Qian. Ultra-short-term power load forecasting based on cluster empirical mode decomposition of CNN-LSTM[J]. *Power System Technology*, 2021, 45(11): 4444-4451(in Chinese).
- [14] TONG Cheng, ZHANG Linghua, LI Hao, et al. Temporal inception convolutional network based on multi-head attention for ultra-short-term load forecasting[J]. *IET Generation, Transmission & Distribution*, 2022, 16(8): 1680-1696.
- [15] 孟衡, 张涛, 王金, 等. 基于多尺度时空图卷积网络与 Transformer 融合的多节点短期电力负荷预测方法[J/OL]. *电网技术*, 2024: 1-14[2024-5-15]. <https://doi.org/10.13335/j.1000-3673.pst.2024.0168>.
- MENG Heng, ZHANG Tao, WANG Jin, et al. Multi-node short-term power load forecasting method based on multi-scale spatiotemporal graph convolution network and Transformer[J/OL]. *Power System Technology*, 2024: 1-14[2024-5-15]. <https://doi.org/10.13335/j.1000-3673.pst.2024.0168>(in Chinese).
- [16] HEWAMALAGE H, BERGMEIR C, BANDARA K. Recurrent neural networks for time series forecasting: current status and future directions[J]. *International Journal of Forecasting*, 2021, 37(1): 388-427.
- [17] KONG Weicong, DONG Zhaoyang, JIA Youwei, et al. Short-term residential load forecasting based on LSTM recurrent neural network [J]. *IEEE Transactions on Smart Grid*, 2019, 10(1): 841-851.
- [18] LI Dan, SUN Guangfan, MIAO Shuwei, et al. A short-term electric load forecast method based on improved sequence-to-sequence GRU with adaptive temporal dependence[J]. *International Journal of Electrical Power & Energy Systems*, 2022, 137: 107627.
- [19] 李玉志, 刘晓亮, 邢方方, 等. 基于 Bi-LSTM 和特征关联性分析的日尖峰负荷预测[J]. *电网技术*, 2021, 45(7): 2719-2730.
- LI Yuzhi, LIU Xiaoliang, XING Fangfang, et al. Daily peak load prediction based on correlation analysis and bi-directional long short-term memory network[J]. *Power System Technology*, 2021, 45(7): 2719-2730(in Chinese).
- [20] RUBASINGHE O, ZHANG Xinan, CHAU T K, et al. A novel sequence to sequence data modelling based CNN-LSTM algorithm for three years ahead monthly peak load forecasting[J]. *IEEE Transactions on Power Systems*, 2024, 39(1): 1932-1947.
- [21] JIANG Lianjie, WANG Xinli, LI Wei, et al. Hybrid multitask multi-information fusion deep learning for household short-term load forecasting[J]. *IEEE Transactions on Smart Grid*, 2021, 12(6): 5362-5372.
- [22] 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.
- DENG Daiyu, LI Jian, ZHANG Zhenyuan, et al. Short-term electric load forecasting based on EEMD-GRU-MLR[J]. *Power System Technology*, 2020, 44(2): 593-602(in Chinese).
- [23] 张淑清, 李君, 姜安琦, 等. 基于 FPA-VMD 和 BiLSTM 神经网络的新型两阶段短期电力负荷预测[J]. *电网技术*, 2022, 46(8): 3269-3279.
- ZHANG Shuqing, LI Jun, JIANG Anqi, et al. A novel two-stage model based on FPA-VMD and BiLSTM neural network for short-term power load forecasting[J]. *Power System Technology*, 2022, 46(8): 3269-3279(in Chinese).
- [24] LI Ke, HUANG Wei, HU Gaoyuan, et al. Ultra-short term power load forecasting based on CEEMDAN-SE and LSTM neural network[J]. *Energy and Buildings*, 2023, 279: 112666.
- [25] 叶剑华, 曹旌, 杨理, 等. 基于变分模态分解和多模型融合的用户级综合能源系统超短期负荷预测[J]. *电网技术*, 2022, 46(7): 2610-2618.
- YE Jianhua, CAO Jing, YANG Li, et al. Ultra short-term load forecasting of user level integrated energy system based on variational mode decomposition and multi-model fusion[J]. *Power System Technology*, 2022, 46(7): 2610-2618(in Chinese).
- [26] 常雨芳, 杨子潇, 潘风, 等. 基于 CEEMDAN-PE-WPD 和多目标优化的超短期风电功率预测方法[J]. *电网技术*, 2023, 47(12): 5015-5025.
- CHANG Yufang, YANG Zixiao, PAN Feng, et al. Ultra-short-term wind power prediction based on CEEMDAN-PE-WPD and multi-objective optimization[J]. *Power System Technology*, 2023, 47(12): 5015-5025(in Chinese).
- [27] 石卓见, 冉启武, 徐福聪. 基于聚合二次模态分解及 Informer 的短期负荷预测[J]. *电网技术*, 2024, 48(6): 2574-2583.
- SHI Zhuojian, RAN Qiwu, XU Fucong. Short-term load forecasting based on aggregated secondary decomposition and informer[J]. *Power System Technology*, 2024, 48(6): 2574-2583(in Chinese).
- [28] ZUO Lingqun, SUN Hongmei, MAO Qichao, et al. Noise suppression method of microseismic signal based on complementary ensemble empirical mode decomposition and wavelet packet threshold[J]. *IEEE Access*, 2019, 7: 176504-176513.
- [29] 李丹, 孙光帆, 缪书唯, 等. 基于多维时序信息融合的短期电力负荷预测方法[J]. *中国电机工程学报*, 2023, 43(S1): 94-106.
- LI Dan, SUN Guangfan, MIAO Shuwei, et al. A short-term power load forecasting method based on multidimensional temporal information fusion[J]. *Proceedings of the CSEE*, 2023, 43(S1): 94-106(in Chinese).
- [30] 孙超, 吕奇, 朱思瞳, 等. 基于双层 XGBoost 算法考虑多特征影响的超短期电力负荷预测[J]. *高电压技术*, 2021, 47(8): 2885-2895.
- SUN Chao, LÜ Qi, ZHU Sitong, et al. Ultra-short-term power load forecasting based on two-layer XGBoost algorithm considering the influence of multiple features[J]. *High Voltage Engineering*, 2021, 47(8): 2885-2895(in Chinese).
- [31] LIU Chuanlu, WANG Shuliang, YUAN Hanning, et al. Detecting unbiased associations in large data sets[J]. *Big Data*, 2022, 10(4): 337-355.
- [32] 张振中, 郭傅傲, 刘大明, 等. 基于最大互信息系数和小波分解的多模型集成短期负荷预测[J]. *计算机应用与软件*, 2021, 38(5): 82-87.
- ZHANG Zhenzhong, GUO Fuao, LIU Daming, et al. Multi-model

- integrated short-term load prediction based on maximum mutual information coefficient and wavelet decomposition[J]. *Computer Applications and Software*, 2021, 38(5): 82-87(in Chinese).
- [33] ZHANG Mingyue, HAN Yang, ZALHAF A S, et al. Accurate ultra-short-term load forecasting based on load characteristic decomposition and convolutional neural network with bidirectional long short-term memory model[J]. *Sustainable Energy, Grids and Networks*, 2023, 35: 101129.
- [34] 江友华, 朱毅轩, 杨兴武, 等. 基于 Hankel-SVD-CEEMDAN 改进阈值的局部放电特征提取方法[J]. *电网技术*, 2022, 46(11): 4557-4567.
JIANG Youhua, ZHU Yixuan, YANG Xingwu, et al. Hankel-SVD-CEEMDAN improved threshold partial discharge feature extraction method[J]. *Power System Technology*, 2022, 46(11): 4557-4567(in Chinese).
- [35] YU Min, NIU Dongxiao, GAO Tian, et al. A novel framework for ultra-short-term interval wind power prediction based on RF-WOA-VMD and BiGRU optimized by the attention mechanism[J]. *Energy*, 2023, 269: 126738.
- [36] LI Huailiang, SHI Jiahao, LI Linjia, et al. Novel wavelet threshold denoising method to highlight the first break of noisy microseismic recordings[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5910110.
- [37] 朱凌建, 荀子涵, 王裕鑫, 等. 基于 CNN-BiLSTM 的短期电力负荷预测[J]. *电网技术*, 2021, 45(11): 4532-4539.
ZHU Lingjian, XUN Zihan, WANG Yuxin, et al. Short-term power load forecasting based on CNN-BiLSTM[J]. *Power System Technology*, 2021, 45(11): 4532-4539(in Chinese).



钟燕

在线出版日期: 2024-09-11。

收稿日期: 2024-05-28。

作者简介:

钟燕(2001), 女, 硕士研究生, 研究方向为电力系统负荷预测, E-mail: zy801025@stu.xhu.edu.cn;

王军(1966), 女, 通信作者, 教授, 硕士生导师, 研究方向为分布式电源和微电网管控技术、电力电子节能技术、新型交流电机控制技术、智能控制技术、膜计算等, E-mail: 745257101@qq.com。

(责任编辑 邱丽萍 马晓华)

附录 A

A1 最大互信息系数方法计算步骤

设 $X = \{x_i, i=1, 2, \dots, n\}$ 和 $Y = \{y_i, i=1, 2, \dots, n\}$ 为数据集中的两个随机变量, n 为样本的数量, 则 X 、 Y 之间的互信息为:

$$I(X, Y) = \sum_{x_i \in X} \sum_{y_i \in Y} p(x_i, y_i) \log_2 \frac{p(x_i, y_i)}{p(x_i)p(y_i)} \quad (\text{A1})$$

式中: $p(x_i, y_i)$ 代表 x_i 、 y_i 联合概率分布; $p(x_i)$ 和 $p(y_i)$ 分别代表 x_i 、 y_i 边缘概率分布。

最大互信息系数 MIC 计算公式为:

$$\begin{cases} \text{MIC}(X, Y) = \max_{xy < B(n)} \frac{I(x_i, y_i)}{\log_2 \min(a, b)} \\ B(n) = n^{0.6} \end{cases} \quad (\text{A2})$$

式中: a 、 b 分别是划分网格横向数量和纵向数量; $B(n)$ 为网格最大值。

CEEMDAN 算法分解步骤:

1) 将 1 组高斯白色噪声添加到原始电力负载序列 $x(t)$ 以构造新信号 $x^{(i)}(t)$ 。

$$x^{(i)}(t) = x(t) + \varepsilon_0 \omega^{(i)} \quad (\text{A3})$$

2) 通过 EMD 方法对 $x^{(i)}(t)$ 进行第 i 次分解 ($i=1, 2, \dots, n$), 得到 n 个本征模态分量, 对所有分量进行求平均得到最终的一阶本征模态分量 $C_{\text{EIMF}_1}(t)$, 并得到一阶残差 $r_1(t)$ 。

$$C_{\text{EIMF}_1}(t) = \frac{1}{n} \sum_{i=1}^n C_{\text{EIMF}_1}^i(t) \quad (\text{A4})$$

$$r_1(t) = x - C_{\text{EIMF}_1}(t) \quad (\text{A5})$$

3) 在 $r_1(t)$ 中加入高斯白噪声, 对得到的新信号进行 EMD 分解得到新一阶模态分量, 求平均后得到最终的二阶模态分量 $C_{\text{EIMF}_2}(t)$ 和二阶残差 $r_2(t)$ 。

$$C_{\text{EIMF}_2} = \frac{1}{n} \sum_{i=1}^n E_1 \{r_1(t) + \varepsilon_1 E_1[\omega^{(i)}(t)]\} \quad (\text{A6})$$

$$r_2(t) = r_1 - C_{\text{EIMF}_2}(t) \quad (\text{A7})$$

4) 重复以上步骤, 直到获得的残差信号为单调函数, 不能继续分解, 算法结束。此时得到最终的 k 阶本征模态分量和最终残差 $r(t)$ 。

$$C_{\text{EIMF}_k} = \frac{1}{n} \sum_{i=1}^n E_{k-1} \{r_{k-1}(t) + \varepsilon_{k-1} E_{k-1}[\omega^{(i)}(t)]\} \quad (\text{A8})$$

$$r(t) = r_{k-1} - C_{\text{EIMF}_k}(t) \quad (\text{A9})$$

5) 经 CEEMDAN 分解后的原始信号 $x(t)$ 表示为:

$$x(t) = \sum_{k=1}^K C_{\text{EIMF}_k}(t) + r(t) \quad (\text{A10})$$

式中: $E_k(\bullet)$ 表示 CEEMDAN 分解得到的第 k 阶分

量; $\omega^{(i)}$ 表示正态分布的高斯白噪声; ε_k 表示高斯白噪声的标准差。

A2 样本熵(Sample Entropy)计算步骤

一般地, 对于长度为 N 的时间序列 $\{x(n)\} = \{x(1), x(2), \dots, x(N)\}$, 样本熵的计算方法如下:

1) 按序号组成一组维数为 m 的向量序列 $X_m(1), X_m(2), \dots, X_m(N-m+1)$, 其中, $X_m(i) = x_m(i), x_m(i+1), \dots, x_m(i+m-1)$, 为从第 i 点开始的 m 个连续的 x 值。

2) 定义向量 $X_m(i)$ 和 $X_m(j)$ 之间的距离 D_{ij} 为两者对应的元素中最大差值的绝对值。即:

$$D_{ij} = (\max_{k=0, \dots, m-1} |x(i+k) - x(j+k)|) \quad (\text{A11})$$

3) 对于给定的 $X_m(i)$ 和 $X_m(j)$ 之间距离小于等于 r 的 $j(1 \leq j \leq N-m)$ 的数目, 并记作 B_i 。对于 $1 \leq j \leq N-m$, 定义 $B_i^m(r)$ 为

$$B_i^m(r) = \frac{1}{N-m-1} B_i \quad (\text{A12})$$

4) 定义 $B^m(r)$ 为

$$B^m(r) = \frac{1}{N-m} \sum_{i=1}^{N-m} B_i^m(r) \quad (\text{A13})$$

5) 增加维数到 $m+1$, 计算 $X_{m+1}(i)$ 与 $X_{m+1}(j)$ 距离小于等于 r 的个数, 记为 A_i 。 $A_i^m(r)$ 定义为

$$A_i^m(r) = \frac{1}{N-m-1} A_i \quad (\text{A14})$$

6) 定义 $A^m(r)$ 为

$$A^m(r) = \frac{1}{N-m} \sum_{i=1}^{N-m} A_i^m(r) \quad (\text{A15})$$

式中: $B_i^m(r)$ 是两个序列在相似容限 r 下匹配 m 个点的概率, 而 $A^m(r)$ 是两个序列匹配 $m+1$ 个点的概率。样本熵定义为

$$\text{SampEn}(m, r) = \lim_{N \rightarrow \infty} \left\{ -\ln \left[\frac{A_i^m(r)}{B^m(r)} \right] \right\} \quad (\text{A16})$$

当 N 为有限值时, 可以用下式计算:

$$\text{SampEn}(m, r) = -\ln \left[\frac{A_i^m(r)}{B^m(r)} \right] \quad (\text{A17})$$

A3 VMD 分解步骤

1) 构造变分约束问题。变分约束表达式为

$$\begin{cases} \min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \\ \text{s.t.} \sum_{k=1}^K u_k(t) = f(t) \end{cases} \quad (\text{A18})$$

式中: $\{u_k\}$ 、 $\{\omega_k\}$ 分别为模态分量集合和为中心频率集合; $\delta(t)$ 为狄拉克分布。

2) 通过增广拉格朗函数将上述等式变分约束优化问题等效为一个无约束优化问题。

$$L(\{u_k\}, \{\omega_k\}, \lambda(t)) = \alpha \sum_{k=1}^K \left\| \left[\delta(t) + \frac{j}{\pi t} \right] u_k(t) e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_{k=1}^K u_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t), \sum_{k=1}^K u_k(t) \right\rangle f(t) \quad (A19)$$

式中: λ 为拉格朗日乘法算子; α 为惩罚因子; $\langle \bullet \rangle$ 为求内积; j 表示虚数单位 (满足将 $j^2 = -1$); $f(t)$ 为待分解序列。

3) 利用交替乘法算子寻优, 不断更新模态分量和中心频率集合, 最终获取各个不同的中心频率分量, 最终获得模态分量 V_{IMF} 。

A4 小波包阈值去噪的基本流程

1) 使用小波包分解对信号进行处理, 获得一组小波包系数。

$$\begin{cases} d_i^{j+1,2n} = \sum_{k \in Z} h_{k-2l} d_k^{j,n} \\ d_i^{j+1,2n+1} = \sum_{k \in Z} g_{k-2l} d_k^{j,n} \end{cases} \quad (A20)$$

式中: k, l 为小波包分解对应层数, n, j 为在当前层数下的节点编号, h_{k-2l} 与 g_{k-2l} 分别为小波包分解中高通滤波器系数和低通滤波器系数, $d_i^{j,n}$ 为在分解过程中第 j 层中第 n 个节点的第 l 个小波包分解系数, $d_i^{j+1,2n}$ 、 $d_i^{j+1,2n+1}$ 为 $d_i^{j,n}$ 对应的两个高频、低频分解量。

2) 对小波包系数进行阈值量化:

$$\begin{cases} d_{(j,i)}, & |d_{(j,i)}| \geq \lambda \\ 0, & |d_{(j,i)}| < \lambda \end{cases} \quad (A21)$$

式中: $d_{(j,i)}$ 为小波包分解系数; λ 为阈值。

3) 重构处理过的小波包系数, 以获得去噪后的信号。

$$d_i^{j,n} = \sum_{k \in Z} (h_{l-2k} d_i^{j+1,2n} + g_{l-2k} d_i^{j+1,2n+1}) \quad (A22)$$

A5 LSTM 基本原理

LSTM 通过引入输入门 i_t 、遗忘门 f_t 和输出门 O_t 三种门控机制来增强记忆和遗忘能力, 有效地解决了传统 RNN 中的梯度消失或爆炸以及长期记忆问题。

1) 遗忘门: 通过 sigmoid 激活函数决定保留多少信息到当前状态 c_t 。

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (A23)$$

式中: $[h_{t-1}, x_t]$ 表示将两个向量合并为一个向量;

W_f 表示遗忘门的权重矩阵; b_f 表示遗忘门的偏置项; $\sigma(\bullet)$ 为 sigmoid 激活函数。

2) 输入门: 控制输入的信息有多少可以被写入记忆单元。

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (A24)$$

$$c'_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (A25)$$

式中: W_i 和 W_c 分别表示输入门和细胞状态的权重矩阵; b_i 和 b_c 分别表示输入门和细胞状态的偏置项; $\tanh(\bullet)$ 为双曲正切函数。

3) 记忆单元: 记忆单元通过保留先前的信息, 同时引入当前的细胞信息来实现长期记忆, 不断对状态进行更新。

$$c_t = f_t * c_{t-1} + i_t * c'_t \quad (A26)$$

式中: $*$ 表示逐元素乘法; c_{t-1} 为上一时刻细胞状态向量。

4) 输出门: 实现对所有先前存在有效信息的筛选并计算出当前的输出。

$$O_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (A27)$$

$$h_t = O_t * \tanh(c_t) \quad (A28)$$

式中: W_o 表示输出门的权重矩阵; b_o 表示输出门的偏置项。

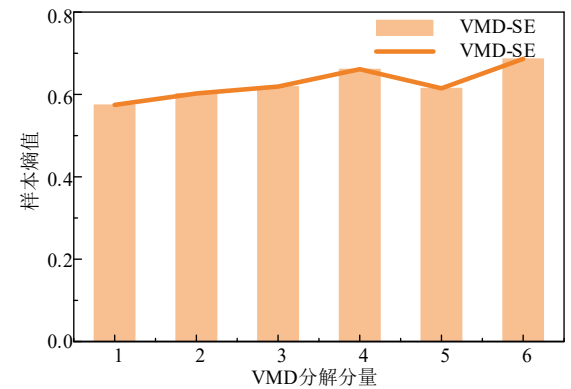
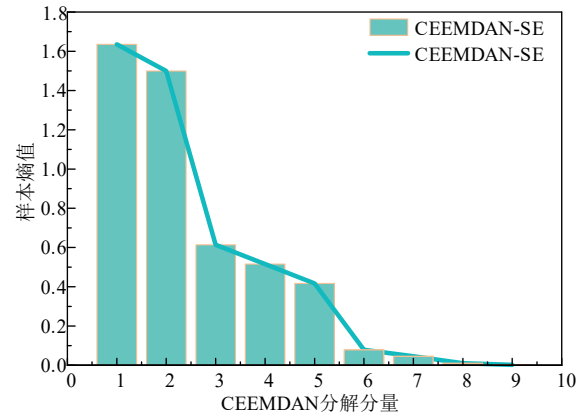


图 A1 二次重构分解分量样本熵值

Fig. A1 Entropy of the sample of the quadratic reconstruction decomposition component

附录 B




图 B1 VMD 分解结果
Fig. B1 VMD decomposition results




图 B2 负荷数据去噪前后对比
Fig. B2 Load data before and after noise reduction

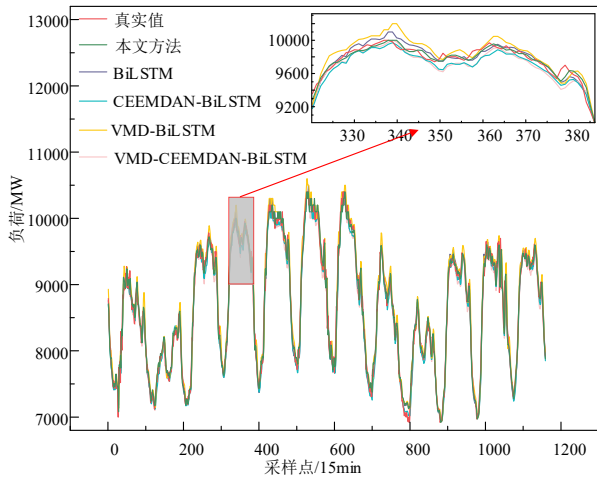


图 B3 极端高温下不同分解方法预测结果
Fig. B3 Prediction of results by different decomposition methods at extreme high temperatures

表 B1 极端高温下不同分解方法误差对比

Model	R^2	E_{RMSE}	E_{MAE}	E_{MAPE}	PA
本文方法	0.983	119.601	87.868	1.024	0.990

VMD-CEEMDAN-BiLSTM	0.977	137.889	102.138	1.171	0.988
CEEMDAN-BiLSTM	0.980	128.098	97.373	1.138	0.989
VMD-BiLSTM	0.969	161.171	124.486	1.428	0.985
BiLSTM	0.981	125.676	94.683	1.099	0.989




图 B4 极端高温下不同模型预测结果
Fig. B4 Predictions by different models at extreme high temperatures

表 B2 极端高温下不同模型预测误差对比

Table B2 Comparison of prediction errors of different models at extreme high temperatures

Model	R^2	E_{RMSE}	E_{MAE}	E_{MAPE}	PA
本文方法	0.983	119.601	87.868	1.024	0.990
CNN-BiGRU	0.979	132.007	104.435	1.231	0.988
TCN-BiLSTM	0.981	125.448	94.209	1.107	0.989
VMD-TCN-Attention	0.982	123.128	93.888	1.092	0.989

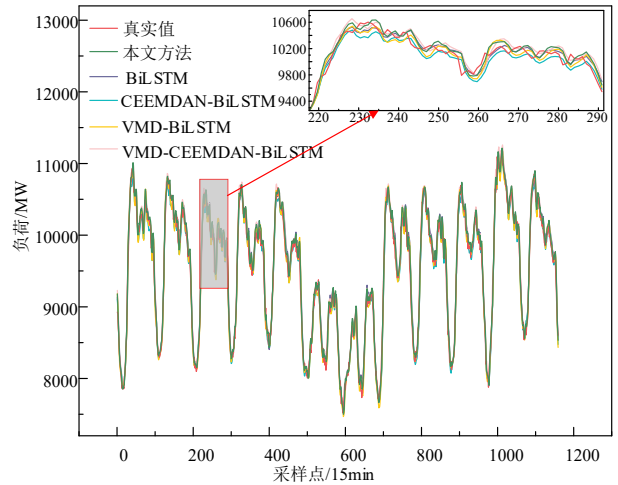


图 B5 极端低温下不同分解方法预测结果
Fig. B5 Prediction results by different decomposition methods at extreme low temperatures

表 B3 极端低温时不同分解方法预测误差对比

Table B3 Comparison of prediction errors of different decomposition methods at extreme low temperatures

Model	R^2	E_{RMSE}	E_{MAE}	E_{MAPE}	PA
本文方法	0.985	106.342	83.177	0.875	0.991
VMD-CEEMDAN-BiLSTM	0.980	121.403	95.678	1.006	0.990
CEEMDAN-BiLSTM	0.984	108.146	86.110	0.905	0.991
VMD-BiLSTM	0.982	114.910	90.927	0.960	0.990

BiLSTM 0.983 113.731 90.113 0.953 0.990




图 B6 极端低温下不同模型预测结果

Fig. B6 Prediction results of different models at extreme low temperatures

表 B4 极端低温下不同模型预测误差对比

Table B4 Comparison of prediction errors of different models at extreme low temperatures

Model	R^2	E_{RMSE}	E_{MAE}	E_{MAPE}	PA
本文方法	0.985	106.343	83.177	0.875	0.991
CNN-BiGRU	0.983	110.411	88.959	0.953	0.990
TCN-BiLSTM	0.979	123.465	98.410	1.060	0.989
VMD-TCN-Attention	0.984	108.986	88.184	0.931	0.991

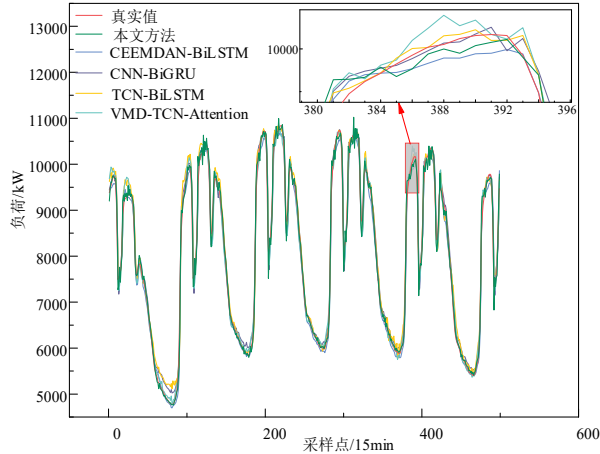


图 B7 泉州市预测结果

Fig. B7 Prediction result in Quanzhou City

表 B5 泉州市预测误差对比

Table B5 Comparison of prediction errors in Quanzhou city

Model	R^2	E_{RMSE}	E_{MAE}	E_{MAPE}	PA
本文方法	0.992	157.295	106.542	1.270	0.987
CEEMDAN-BiLSTM	0.990	174.241	133.129	1.640	0.983
CNN-BiGRU	0.990	176.844	129.673	1.651	0.983
TCN-BiLSTM	0.990	179.005	139.495	1.866	0.982
VMD-TCN-Attention	0.991	171.630	124.440	1.535	0.985
对比模型均值	0.990	175.43	131.684	1.673	0.983

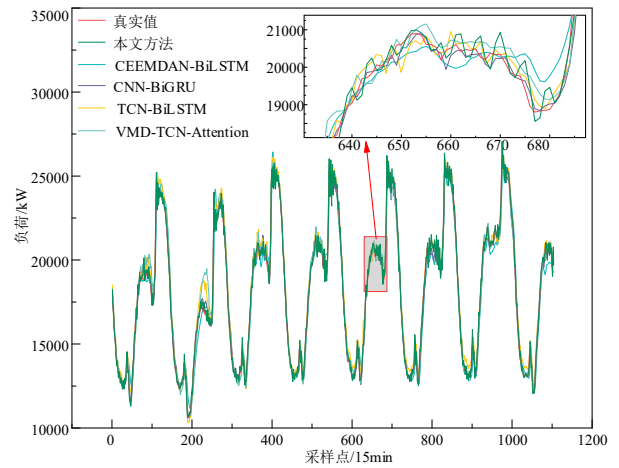


图 B8 得土安市预测结果

Fig. B8 Tétouan city forecast results

表 B6 得土安市预测误差对比

Table B6 Comparison of prediction errors in Tétouan city

Model	R^2	E_{RMSE}	E_{MAE}	E_{MAPE}	PA
本文方法	0.996	248.719	184.105	1.009	0.990
CEEMDAN-BiLSTM	0.994	299.443	231.988	1.304	0.987
CNN-BiGRU	0.992	320.376	258.693	1.549	0.985
TCN-BiLSTM	0.994	301.529	217.386	1.221	0.988
VMD-TCN-Attention	0.992	365.977	268.784	1.491	0.985
对比模型均值	0.993	321.831	244.212	1.391	0.986