

DOI:10.19651/j.cnki.emt.2416156

基于模态分解和 TCN-BiLSTM 的风电功率预测^{*}

冯俊磊 吕卫东 段雪艳 张幽迪

(兰州交通大学数理学院 兰州 730070)

摘要: 风电功率的准确预测对于能源系统的稳定运行和电力调度方面具有重要作用。由于风电功率序列具有随机性、间歇性和非线性的特点,使用传统预测以及单一预测模型往往会存在预测精度较低的问题,且容易受到噪声干扰。为了提升风电功率预测的准确性,本文提出了一种 CEEMDAN 分解技术与神经网络模型相结合的方法。首先将风电功率序列用 CEEMDAN 方法分解为若干数量的本征模态分量,通过样本熵值来计算每个模态分量的复杂度,根据样本熵值大小将不同的模态分量重组为重构的子序列。将中高频序列数据使用 BiLSTM 模型来进行预测,而中低频序列数据则采用 TCN 模型来预测。最后,将不同模型的预测值叠加得到最终的预测值。通过仿真实验,结果表明本文模型在评价指标 RMSE、MAE、SMAPE 取值均最低,R 方值最高,这几个指标的取值均值分别为 91.413 2 MW、53.517 3 MW、22.263 8 MW、0.980 7,均优于对比模型,说明本文模型具有较高的预测精度。

关键词: 风电功率预测;TCN;模态分解;BiLSTM;组合模型

中图分类号: TM614;TN-9 **文献标识码:** A **国家标准学科分类代码:** 470.4047

Wind power prediction based on mode decomposition and TCN-BiLSTM

Feng Junlei Lyu Weidong Duan Xueyan Zhang Youdi

(School of Mathematics and Physics, Lanzhou Jiaotong University, Lanzhou 730070, China)

Abstract: Accurate prediction of wind power plays an important role in the stable operation of the energy system and power dispatch. Due to the stochastic, intermittent, and nonlinear characteristics of wind power sequences, the use of traditional prediction and a single prediction model often suffers from low prediction accuracy and is easily interfered by noise. In order to improve the accuracy of wind power prediction, a method combining CEEMDAN decomposition technology and neural network model is proposed in this paper. Firstly, the wind power sequence is decomposed into a number of intrinsic mode components by the CEEMDAN method. The complexity of each mode component is calculated by the sample entropy value, and the different intrinsic mode components are reorganized into reconstructed subsequences based on the sample entropy values. Middle and high-frequency sequence data are predicted using the BiLSTM model, while middle and low-frequency sequence data are predicted using the TCN model. Finally, the predicted values from the different models are combined to obtain the final prediction. Through simulation experiments, the results demonstrate that the model proposed in this paper achieves the lowest values in the evaluation metrics RMSE, MAE, and SMAPE, and the highest value in the R-squared metric. The average values of these indicators are 91.413 2 MW, 53.517 3 MW, 22.263 8 MW, and 0.980 7, respectively, which are better than those of the comparison models. This indicates that the model presented in this paper has high accuracy.

Keywords: wind power prediction;TCN;mode decomposition;BiLSTM;combined model

0 引言

风力发电作为清洁能源的一种,在我国的能源组成中发挥着越来越重要的作用。但是由于风速存在随机性,非线性和间接性的特点,对于风电装置来说难以实现对电网

的监控和控制,因此进行准确和及时的风电功率预测在提高风力发电输出功率,确保电网设备的安全性和可靠性有着重要的作用。

国内外的许多学者针对风电功率预测进行了广泛而深入的研究,根据不同的预测方法大致可以将这些方法分为

收稿日期:2024-06-01

* 基金项目:国家自然科学基金(11962011)项目资助

3 大类:基于物理的预测方法,基于统计的预测方法和基于人工智能的预测方法。基于物理的预测方法^[1-2]主要是基于气象学和风力发电机组的工作原理来建立数学模型,在实际电网中计算效率低下,难以满足风电功率实时预测需求。统计预测方法^[3-5]是利用统计学模型对历史时间序列数据进行建模,得到关于风电功率的预测模型,相比物理预测模型预测精度有了一定程度的提高。随着计算机的发展和软硬件技术的提高,越来越多的学者提出将人工智能技术应用到序列预测中,并结合信号分解方法来降低预测序列的复杂度。深度神经网络模型可以更好的捕捉数据之间的关系,大大增强了对非线性和非平稳数据的预测能力。朱乔木等^[6]将长短期记忆神经网络(long short-term memory network, LSTM)应用于风电功率预测,但单一的 LSTM 模型随着时间序列长度的增加,预测精度也会降低。牛哲文等^[7]提出了一种将卷积神经网络(convolutional neural network, CNN)和门控循环单元(gated recurrent unit, GRU)相结合的深度学习模型,虽然精度有一定程度的提高,但由于层数过多因此会导致参数增加以及预测值较为保守的问题。赵建利等^[8]将 CNN 和 LSTM 相结合,通过 CNN 提取风电功率相关数据的特征,将其作为 LSTM 的输入信息进而对序列进行预测,其中过多的隐含层也会出现过拟合现象进而影响模型精度。Xiang 等^[9]将自注意力机制引入时域卷积神经网络(temporal convolutional neural, TCN),并结合 LSTM 对风电功率进行预测,通过与其他方法相比预测误差有进一步降低。在时间序列预测领域,随着模态分解技术的广泛应用,其与其他模型的深度融合已成为众多研究者竞相探索的热点方向。李俊杰等^[10]提出一种集合经验模态分解(ensemble empirical mode decomposition, EEMD)和支持向量回归(support vector regression, SVR)结合的模型预测方法,结果表明所提模型能够实现非平稳序列的可靠分解,预测效果得到了改善,但 EEMD 中的白噪声标准差、SVR 中的核函数系数和惩罚因子等参数的确定可能需要大量的实验和调整。Wang 等^[11]通过互补集合经验模态分解(complementary ensemble empirical mode decomposition, CEEMD)来降低序列的非平稳性,并结合样本熵(sample entropy, SE)对子序列进行重构以降低计算复杂度,最后通过和声搜索(harmony search, HS)结合带核的极限学习机(extreme learning machine with kernel, KELM)混合模型来对风电序列数据进行预测,仍然具有模型容易过拟合和计算量过大等问题。Zhang 等^[12]提出了一种基于自适应噪声的完备集合经验模态分解(complete ensemble empirical mode decomposition with adaptive noise, CEEMDAN)和 LSTM 组合的超短期风电预测模型,与其他预测模型相比,所提方法具有更高的短期风电功率预测精度。Li 等^[13]首先通过 CEEMDAN 对风电序列进行分解,之后又利用改进了的传统卷积神经网络结构并结合双向长短期记忆神经网络(bidirectional long

short-term memory, BiLSTM)进一步提取风电数据之间的特征,叠加了各分量的预测结果,得到最终的风电预测值。

上述模型虽然在风电功率预测方面表现出较高的精度和适应性,但同时也存在计算资源消耗大和模型解释性差等潜在缺点。本文在上述研究内容的基础上,根据风电功率序列数据的非平稳以及复杂性,首先采用信号分解中的 CEEMDAN 分解策略,对原始风电功率序列数据进行深入分析,以识别并提取出一系列具有不同频率特征子序列。然后使用样本熵对于分解后的特征子序列计算样本熵值,并按不同取值进行序列重组,以降低计算的复杂度,最后将重组序列使用 TCN-BiLSTM 组合模型进行预测。TCN 模型在很大程度上具有缓解梯度消失和爆炸的优势,能够较好的捕捉长期的时间序列关系,而 BiLSTM 模型能够同时利用时序以前和现在的信息,理解序列的趋势。经组合模型预测后,将预测值整合得到最终的风电功率预测结果。最后通过实例证明了所提方法能够有效提高风电功率序列的预测精度,通过多次实验验证也保证了模型的泛化能力和鲁棒性。

1 理论基础

1.1 CEEMDAN 模态分解算法

风电功率序列数据具有非平稳非线性的特征,对原始数据进行 CEEMDAN 分解^[14],可以弱化风电功率序列数据的非平稳性,捕捉序列的局部特征。它是在传统经验模态分解方法上的改进,克服了端点效应和模态混叠现象等问题。另外该方法还引入了能处理正负高斯白噪声的信号,对集合经验模态分解算法进行了改进,降低了信号重构的误差。其分解过程如下:

1)向原始序列信号 $s(t)$ 加入 N 次高斯白噪声,构造得到共 N 个预处理序列 $s_n(t)$ 。

$$s_n(t) = s(t) + \epsilon_0 \delta_n(t) \quad (1)$$

式中: ϵ_0 表示的是高斯白噪声的权值系数, $\delta_n(t)$ 表示第 n 次处理时的高斯白噪声。

2)首先对所有预处理过的时间序列 $s_n(t)$ 进行经验模态分解(empirical mode decomposition, EMD),以得到第一个本征模态函数(intrinsic mode function, IMF)分量 $c_1^n(t)$,然后取其平均值作为 CEEMDAN 分解的第一个 IMF 分量 $c_1(t)$,在此期间得到第一个残差序列 $r_1(t)$,其各自的表达式分别如下:

$$c_1(t) = \frac{1}{N} \sum_1^N c_1^n(t) \quad (2)$$

$$r_1(t) = s(t) - c_1(t) \quad (3)$$

3)接着向残差序列 $r_1(t)$ 引入高斯白噪声生成 N 个新的序列 $r_1(t) + \epsilon_1 E_1(\delta_n(t))$,对这 N 个序列继续实施 EMD 分解,取其均值得到第 2 个 IMF 分量 $c_2(t)$,并作差得到 $r_2(t)$,那么其第 m 阶段的残差如下:

$$r_m(t) = r_{m-1}(t) - c_m(t) \quad (4)$$

4)在上式基础上,对 $r_m(t) + \varepsilon_m E_m(\delta_n(t))$ 进行 N 次 EMD 分解,就得到了 CEEMDAN 模态分解后的第 $m+1$ 个 IMF 序列。

5)重复以上步骤 1)~4),直到分解停止,其最后的残差序列为:

$$R(t) = s(t) - \sum_1^N c_m(t) \quad (5)$$

原始信号序列 $s(t)$ 经过 CEEMDAN 分解后的表达式为:

$$s(t) = R(t) + \sum_1^M c_m(t) \quad (6)$$

1.2 样本熵

样本熵^[15]是用来衡量序列复杂度的表征函数,其取值能够直观的反映序列的复杂性,样本熵值越小,序列自我相似性越高,也就说明序列越不复杂,其取值越大说明序列越复杂。样本熵用 $SampEn(m, r, N)$ 来表示,其中 N 为数据序列的长度, m 为维数, r 为相似度容限。其公式定义如下:

$$SampEn(m, r) = \lim_{N \rightarrow \infty} \{-\ln[B^{m+1}(r)/B^m(r)]\} \quad (7)$$

当 N 有限时,上述样本熵的定义式子可以表示为:

$$SampEn(m, r, N) = \{-\ln[B^{m+1}(r)/B^m(r)]\} \quad (8)$$

上述公式中的 $B^{m+1}(r)$ 和 $B^m(r)$ 是两个时间序列在阈值 r 处匹配 $m+1$ 或 m 点的概率。样本熵相比近似熵具有更好的一致性并且对于数据序列的丢失不敏感,比较适合用来评价序列的复杂程度。

1.3 时域卷积网络

TCN 在保留 CNN 对数据空间特征的提取能力的前提下,通过网络结构的改进增强了其对时间序列信息的处理能力。TCN^[16-17]有效的避免了梯度消失和梯度爆炸的问题,具有占用内存低、梯度稳定、并行性良好和感受野灵活的优点。其模型结构如图 1 所示。




图 1 膨胀因果卷积

Fig. 1 Dilated causal convolution

假设输入序列是 $X = \{x_0, x_1, x_2 \dots x_T\}$, 卷积核 $f: \{0, \dots, k-1\} \in \mathbb{R}$, 定义序列元素 s 的膨胀卷积运算 F 为:

$$F(s) = \sum_{i=0}^{k-1} f(i) \cdot X_{s-d \cdot i} \quad (9)$$

其中, d 为扩张因子, k 为卷积核大小,通过对于网络

中卷积核的大小、模型的深度和扩张因子等超参数进行调整就可以实现对指定长度序列的整体感知,对于序列数据的特征提取能力显著高于卷积神经网络。其独特的残差连接结构能够使得 TCN 网络可以跨层传递信息,这样就避免了因层数过多而导致信息丢失的问题。TCN 中的残差模块包括了两层膨胀因果卷积,并使用了权重归一化和 Dropout 来防止模型过拟合。

1.4 双向长短期记忆网络

BiLSTM^[18-19]是在 LSTM 基础上得到的,通过正向的 LSTM 和反向的 LSTM 相结合,可以很好的探索未来,过去时刻数据之间的潜在联系,正向的传播层单元学习当前输入的未来信息,反向的传播层学习当前输入的历史信息,其结构如图 2 所示。




图 2 双向长短期记忆神经网络结构图

Fig. 2 Structural diagram of bidirectional long and short-term memory neural network

其最终输出由下式得到:

$$\begin{cases} \vec{h}_t = LSTM(x_t, \vec{h}_{t-1}) \\ \overleftarrow{h}_t = LSTM(x_t, \overleftarrow{h}_{t+1}) \\ y_t = W_1 \vec{h}_t + W_2 \overleftarrow{h}_t + b_t \end{cases} \quad (10)$$

式中: \vec{h}_t 表示的是正向 LSTM 的输出向量, \overleftarrow{h}_t 表示的反方向的 LSTM 的输出向量, W_1 和 W_2 分别表示的是正向和反向的参数权重, b_t 表示偏置, BiLSTM 的最终输出由两个方向学习到的特征进行拼接,从而提取时间序列的前向和后向依赖关系,不仅可以增加输入数据的利用率还能有效提高模型的预测效果。

2 基于 CEEMDAN-TCN-BiLSTM 模型的构建

2.1 模型构建流程

风电功率序列数据的原始序列的复杂程度较高,为了能够更好的捕捉序列之间的依赖关系,提高模型预测效果。本文提出了一种基于 CEEMDAN 分解和 TCN-BiLSTM 结合的风电功率预测模型,其模型构建步骤如下:

1)输入原始的风电功率序列数据,对原始风电功率数据进行预处理,去除重复值和异常值,对于存在的缺失值使用拉格朗日插值法进行填充,并将原始序列数据进行标准

化处理,以消除原始序列数据量纲,防止后续模型训练过程中出现数值爆炸情况。由于原始序列数据复杂度高,有着极强的随机性和非线性的特征,使用 CEEMDAN 将原始序列分解为若干子序列,以降低序列的随机性、复杂性和非线性。

2)通过样本熵来计算各分解后的子序列的样本熵值,以此来评估不同序列的复杂性程度,将取值相近的序列进行重构,得到不同频率大小的重构序列,将其作为模型的输入,然后使用滑动窗口分别对不同频率的分量构建训练样本数据。

3)对于步骤 2)构建的模型训练样本数据,根据其频率大小分别将其输入到神经网络模型,得到不同网络下的预测结果。对于重构后的中低频序列,使用时域卷积神经网络 TCN 模型来对重构序列进行预测,对于重构后的中高频序列,使用 BiLSTM 模型来对重构序列进行预测,最后将各重组序列的预测结果进行合并拼接得到最终的模型预测结果。

4)对模型的预测精度进行分析评价,在模型预测结果输出后,本文使用通过均方根误差(RMSE)、平均绝对误差(MAE)、对称平均绝对百分比误差(SMAPE)以及 R 方值作为模型评价指标。其中 RMSE、MAE、SMAPE 取值越小,模型预测精度越高。较高的 R 方值通常意味着模型具有更好的拟合效果和预测能力。根据以上步骤,组合预测模型流程图如图 3 所示。

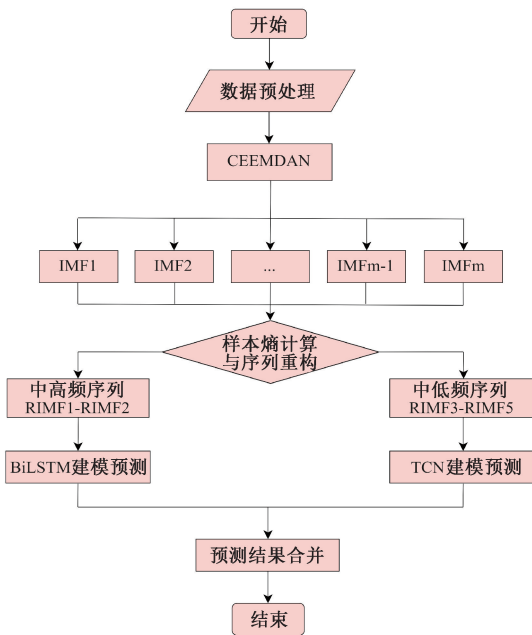


图 3 组合预测流程图

Fig. 3 Combined prediction flow chart

2.2 模型评价标准

在预测任务中通常使用回归模型中的评价指标来评价模型预测结果和实际值之间的差距。在本文中通过

RMSE、MAE、SMAPE 以及 R 方值来作为评估模型的关键性指标。具体来说, RMSE、MAE、SMAPE 这 3 个指标的数值越小说明模型的预测效果越好,即预测值与实际值更加接近。相反, R 方值越大说明模型的拟合度越好,预测效果更优。这些指标共同构成了模型的评价指标体系,共同衡量预测值和真实值的接近程度。其计算式子如下:

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

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (12)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y}_i)^2} \quad (13)$$

$$SMAPE = \frac{1}{N} \sum_{i=1}^N \frac{|y_i - \hat{y}_i|}{(|y_i| + |\hat{y}_i|)/2} \times 100\% \quad (14)$$

式中: y_i 表示原始风电功率数据, \bar{y}_i 表示的是风电功率数据的平均值, \hat{y}_i 表示的是模型的预测值。

3 实例分析

3.1 数据集描述

本文采用比利时电网公司 Elia 公布的风力发电功率数据作为实例研究的数据,具体时段为 2022 年 4 月 1 日 00 时 00 分到 2022 年 7 月 31 日 23 时 45 分。该数据以 15 分钟为一个采集节点,记录风力发电功率的具体取值情况,每天会采集到 96 条数据,共收集了 11 712 条数据,为本文的实例分析提供了坚实的基础。其原始风电功率序列数据分布如图 4 所示。




图 4 原始风电功率序列

Fig. 4 Original wind power sequence

直接使用原始序列数据进行运算可能会产生数值爆炸的问题,特别是对于长序列和高维度数据,直接建模会显著增加计算的复杂度和计算资源。为了减小运算压力和提高模型训练的效率,所以在进行实验时首先使用最大最小值标准化方法来消除数据量纲,将原始数据进行归一化,其计算如下:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (15)$$

式中: x' 为归一化处理后的数据, x 为原始风电功率数据, x_{\max} 和 x_{\min} 分别为风电功率序列数据的最大值和最小值。

3.2 实验环境

本文模型和对比模型均在相同实验环境下进行,实验时的软件环境为: Python3.10、PyCharm2023.2.1 专业版以及深度学习框架 Tensorflow2.10.0,硬件环境为:处理器为 12th Gen Intel(R) Core(TM) i7-12650H,内存 RAM 为 16 G、所用显卡为 NVIDIA GeForce RTX4060。本文将 11 712 条原始数据按照 8:2 的比例划分为训练集和测试集。

3.3 数据分解及序列重构

在进行原始数据分解之前,首先使用最大最小归一化将风电功率序列数据进行标准化,由于 CEEMDAN 可以根据序列数据自适应的得到本征模态分量的个数,此处将 CEEMDAN 分解时的参数设置^[20]为:添加噪声次数为 100 次,添加噪声尺度 0.05,原始数据经过分解后得到多个子序列,其分解结果如图 5 所示。

图 5 中第 1 行折线图表示的是原始序列数据,第 2 行到第 12 行表示的是经过 CEEMDAN 分解之后得到的各 IMF 子序列。从图 5 可以看出,分解后的序列相比于原始序列的复杂度和随机性均有所降低,序列的波动程度也依次降低,序列逐渐趋于平稳。为了更直观的对分解后的序列复杂度进行分析,本文通过使用样本熵来对序列复杂度进行计算。在样本熵公式中将其中的参数 m 设置为 1,参数 r 设置为 0.1,在此情形下,通过计算不同本征模态分量的样本熵值如图 6 所示。

从上述分解后的子序列样本熵的取值可以看出经过 CEEMDAN 分解后的子序列的复杂度是逐渐降低的,频率波动的程度和随机性也在逐渐降低,且不同序列之间的复杂度有着相似性。

通过比较不同子序列的样本熵的取值和相似程度对分解后的子序列进行重构,其中 IMF1、IMF2、IMF3 的样本熵值接近且取值最高,将其重构为高频率序列。由于 IMF4 的取值相比之前的 IMF1~IMF3 的值有所下降且取值大于 0.5,将其重构为中高频序列。IMF5 的取值接近于 0.5,将其重构为中频率序列,将 IMF6 重构为中低频率序列。IMF7~IMF11 的样本熵值均小于 0.1 且其取值较接近,因此将其重构为低频率序列。经过 CEEMDAN 分解后的子序列的重构序列如表 1 所示。

重构序列与原始序列的对比图如图 7 所示。

将分解后的子序列根据复杂性不同程度进行重组,得到不同频率分布的重组序列,每一组序列都呈现出不同的频率特性。这样能够针对重组序列的不同的频率特性来建立合适的预测模型,不仅降低了多个子序列预测结果合并后可能出现的误差,也可以有效的对风电功率序列数据进

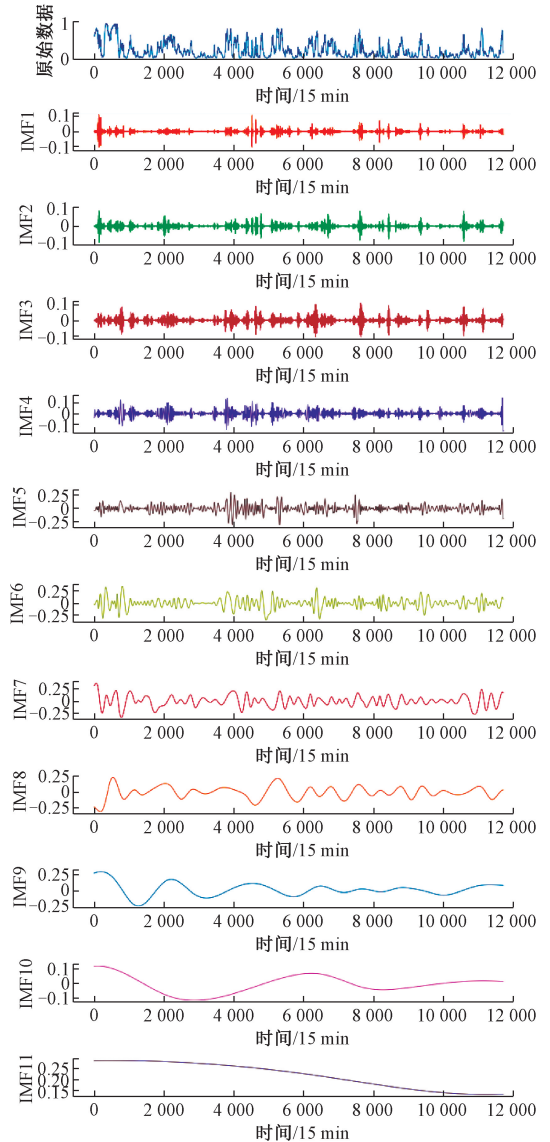


图 5 风电功率的分解结果

Fig. 5 Decomposition results of wind power

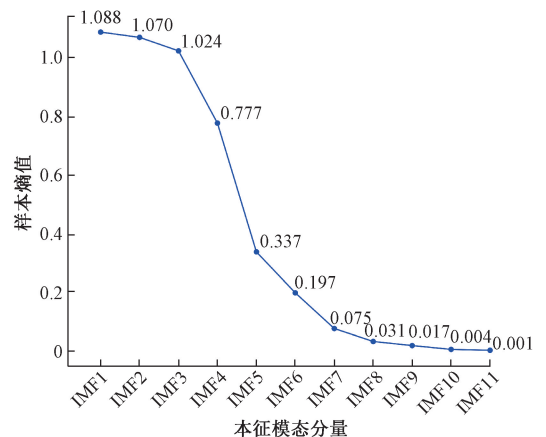


图 6 各模态分量的样本熵值

Fig. 6 Sample entropy of each mode component

表 1 重构子序列

Table 1 Reconstructed subsequence

重构序列组合方案	高频 RIMF1 IMF1~ IMF3	中高频 RIMF2 IMF4	中频 RIMF3 IMF5	中低频 RIMF4 IMF6	低频 RIMF5 IMF7~ IMF11
----------	---------------------------	-------------------	------------------	-------------------	----------------------------




图 7 重构序列图

Fig. 7 Reconstructed sequence diagram

行降噪,进而提高模型的预测精度。

3.4 模型参数设置

在将重构子序列数据分别输入到 TCN 和 BiLSTM 神经网络模型时,所用模型的超参数设置^[21]如表 2 所示。

在进行模型训练之前,需要先将原始数据转化为可训练形式,本文使用滑动窗口机制来将原始序列构造为训练样本,其构建流程如图 8 所示。为了适应预测任务的具体需求,在此过程中定义模型输入的滞后时间步长 T ,需要预测的时间步长 t ,使用 1 到 T 时刻的数据来预测 $T+t$ 时刻的数据,依次类推。

在本文中上述模型输入的滞后时间步长 T 设置为 8,预测的时间步长设置为 1,在此基础上构建本文的训练样本来进行预测模型的训练。

3.5 对照实验及模型性能比较

为了能够更加直观且准确的评估模型性能和预测精

表 2 模型超参数设置

Table 2 Model hyperparameter settings

模型	具体参数	数值
TCN	滤波器数量	64
	滤波器大小	3
	激活函数	relu
	残差单元数量	2
	Dropout	0.4
	优化器	Adam
BiLSTM	迭代次数	200
	LSTM 单元数	64
	隐层数	1
	Dropout	0.2
	激活函数	relu
	优化器	Adam
	迭代次数	200




图 8 滑动窗口机制

Fig. 8 Sliding window mechanism

度,通过建立模型 BP、LSTM、EMD-TCN、EMD-LSTM 和组合模型 CEEMDAN-TCN、CEEMDAN-BiLSTM 来与本文所提模型的预测结果进行对比实验,其中超参数设置均和本文所提模型对的超参数设置保持一致,为了降低模型训练随机性,提高模型的鲁棒性和泛化能力,分多次运行并取其平均值得到各模型的评价指标分别如表 3 所示。

表 3 不同模型的评价指标

Table 3 Evaluation index of different models

模型	RMSE/ MW	MAE/ MW	SMAPE/ MW	R^2
BP	240.871 5	154.892 5	54.348 8	0.865 9
LSTM	185.809 9	110.587 1	32.203 8	0.920 2
EMD-TCN	123.807 1	88.658 0	33.051 5	0.964 3
EMD-LSTM	125.107 2	83.451 3	30.297 2	0.963 8
CEEMDAN-TCN	96.901 8	58.922 9	24.117 0	0.978 2
CEEMDAN-BiLSTM	95.832 1	58.618 4	24.840 9	0.978 8
本文模型	91.413 2	53.517 3	22.263 8	0.980 7

通过表 3 可知,本文所提模型在评价指标 RMSE、MAE、SMAPE 的取值都最低, R^2 值最高,说明本文所提模型在提高模型预测精度方面性能最优。相比于单个模型来说,所提的组合模型充分发挥了各子模型的优势,能够较好

的避免序列之间的依赖关系。相比于 EMD 分解来说, CEEMDAN 分解将原始序列复杂度降低的同时, 通过多次对原始信号添加不同的噪声进行分解, 从而改善了 EMD 的噪声抑制能力和分解的不稳定性。因此, CEEMDAN 在实际应用中能够更好地处理含有噪声的信号, 提供了更准确的分解结果。

本文所提模型在风电功率序列预测中的评价指标 RMSE、MAE、SMAPE 在所有的对比模型中取值最低, 与 EMD-TCN 模型相比, RMSE 降低了 26.16%, MAE 降低了 39.64%, SMAPE 降低了 32.64%; 与 EMD-LSTM 模型

相比, RMSE 降低了 26.93%, MAE 降低了 35.87%, SMAPE 降低了 26.52%; 与 CEEMDAN-TCN 相比, RMSE 降低了 5.66%, MAE 降低了 9.17%, SMAPE 降低了 8.32%; 与 CEEMDAN-BiLSTM 模型相比, RMSE 降低了 4.61%, MAE 降低了 8.70%, SMAPE 降低了 10.37%。在与可决系数 R 方的对比中, 本文所提模型在对比模型中取值最高, 说明所提模型预测精度最高, 预测值较高程度的接近于实际值。通过将各对比实验的风电功率预测值和本文模型的预测值以及实际值分别在同一张图上进行比较, 得到最终的预测结果和实际值的对比图如图 9 所示。




图 9 各模型预测值和实际值对比图

Fig. 9 Comparison of predicted and actual values for each model

图 9 中本文所提模型的预测值和实际值之间的误差最小, 也说明了本文所提模型的性能最好, 在风电功率序列数据上预测精度最高。为优化电力资源配置, 降低风电系统运行风险以及电网设备的可靠性等方面发挥了重要作用。

4 结 论

风电功率序列的预测对于改善风电场电力调度策略, 电力系统中设备的安全稳定运行等方面都具有重要意义。本文提出了一种 TCN 和 BiLSTM 结合的组合模型来进行风电功率序列的预测。

利用 CEEMDAN 分解算法对原始序列进行模态分解, 可得到不同频率的子序列, 能够更好的探究序列之间的相互依赖关系, 降低了序列的复杂性。将子序列按照复杂程度进行重组后分别用 TCN 和 BiLSTM 模型进行序列预测, 并将各自预测结果叠加得到最终的预测序列。

通过实验对应的评价指标来看, 组合模型充分发挥了单个预测模型的优势, 所提模型的预测误差最小, 模型性

能最好。通过消融实验和对比实验也说明了模态分解将原始复杂序列分解为若干复杂度较低的子序列对于提高模型预测精度有一定的意义。相比单一模型和部分组合模型来说本文模型有效提高了预测精度, 验证了组合模型的优越性, 具有一定的参考价值, 能够为风电并网, 提高电力系统稳定性和可靠性等方面发挥一定作用。

由于样本的局限性, 只研究了风电功率单序列预测问题, 下一步可以对样本进行完善, 将该序列和其他气象条件例如温度、气压等因素一起来探究气象因素对风电功率预测精度的影响。

参考文献

- [1] LIAO K, LU D, WANG M, et al. A low-pass virtual filter for output power smoothing of wind energy conversion systems [J]. IEEE Transactions on Industrial Electronics, 2022, 69(12): 12874-12885.
- [2] 李湃, 管晓宏, 吴江. 基于大气动力模型的多风电场出力场景生成方法 [J]. 中国电机工程学报, 2015, 35(18): 4581-4590.

- LI P, GUAN X H, WU J. Output scenario generation method for multiple wind farms based on Atmospheric Dynamic Model[J]. Proceeding of the CSEE, 2015, 35(18):4581-4590.
- [3] 曹俊波,周任军,邓学华,等.考虑优化 ARIMA 模型差分次数的风功率预测[J].电力系统及其自动化学报,2019,31(1):105-111.
CAO J B, ZHOU R J, DENG X H, et al. Wind power prediction considering optimized ARIMA model difference counts[J]. Journal of Power System and Automation,2019,31(1):105-111.
- [4] 杨茂,黄宾阳,江博,等.基于卡尔曼滤波和支持向量机的风电功率实时预测研究[J].东北电力大学学报,2017,37(2):45-51.
YANG M, HUANG B Y, JIANG B, et al. Research on real-time prediction of wind power based on Kalman filter and support vector machine[J]. Journal of Northeast Power University,2017,37(2):45-51.
- [5] YANG X, MA X, KANG N, et al. Probability interval prediction of wind power based on kde method with rough sets and weighted markov chain[J]. IEEE Access,2018,6:51556-51565.
- [6] 朱乔木,李弘毅,王子琪,等.基于长短期记忆网络的风电场发电功率超短期预测[J].电网技术,2017,41(12):3797-3802.
ZHU Q M, LI H Y, WANG Z Q, et al. Ultra short-term prediction of wind farm generation power based on long and Short-term memory network[J]. Grid Technology,2017,41(12):3792-3802.
- [7] 牛哲文,余泽远,李波,等.基于深度门控循环单元神经网络的短期风功率预测模型[J].电力自动化设备,2018,38(5):36-42.
NIU ZH W, YU Z Y, LI B, et al. Short-term wind power prediction model based on deep gated on long short-term memory network[J]. Power Automation Equipment,2018,38(5):36-42.
- [8] 赵建利,白格平,李英俊,等.基于 CNN-LSTM 的短期风电功率预测[J].自动化仪表,2020,41(5):37-41.
ZHAO J L, BAI G P, LI Y J, et al. Short-term wind power prediction based on CNN-LSTM[J]. Automation Instrumentation,2020,41(5):37-41.
- [9] XIANG L, LIU J, YANG X, et al. Ultra-short term wind power prediction applying a novel model named SATCN-LSTM[J]. Energy Conversion and Management, 2022, 252: 115036.
- [10] 李俊杰,石强,胡群勇,等.基于 EEMD-SVR 模型的风电功率预测[J].电器与能效管理技术,2020(11):22-28.
LI J J, SHI Q, HU Q Y, et al. Wind power prediction based on EEMD-SVR model[J]. Electrical and Energy Efficiency Management Technology, 2020(11):22-28.
- [11] WANG K, NIU D, SUN L, et al. Wind power short-term forecasting hybrid model based on CEEMD-SE method[J]. Processes, 2019, 7(11): 843.
- [12] ZHANG C, YANG Z, GAO S. Short term wind power prediction based on CEEMDAN-LSTM[J]. Academic Journal of Science and Technology, 2023, 6(3): 77-81.
- [13] LI Z, XU R, LUO X, et al. Short-term wind power prediction based on modal reconstruction and CNN-BiLSTM[J]. Energy Reports, 2023, 9: 6449-6460.
- [14] ZHANG Y, CHEN Y. Application of hybrid model based on CEEMDAN, SVD, PSO to wind energy prediction[J]. Environmental Science and Pollution Research,2021,29(15):22661-22674.
- [15] ZHU S, WANG X, MEI D, et al. CEEMD-MR-hybrid model based on sample entropy and random forest for SO₂ prediction[J]. Atmospheric Pollution Research, 2022, 13(3): 101358.
- [16] SHENG Y, WANG H, YAN J, et al. Short-term wind power prediction method based on deep clustering-improved Temporal Convolutional Network[J]. Energy Reports, 2023, 9: 2118-2129.
- [17] 李春辉,张瑛琪,孙洁.融合 2 维卷积与注意力以预测 PM_{2.5} 浓度的 S-TCN 模型[J].国外电子测量技术,2024,43(1):77-86.
LI CH H, ZHANG Y Q, SUN J. An S-TCN model combining 2-dimensional convolution and attention to predict PM_{2.5} concentration[J]. Foreign Electronic Measurement Technology, 2024,43(1):77-86.
- [18] JOSEPH L P, DEO R C, PRASAD R, et al. Near real-time wind speed forecast model with bidirectional LSTM networks[J]. Renewable Energy, 2023, 204: 39-58.
- [19] 袁建华,蒋文军,李洪强,等.基于 SSA-BiLSTM 非线性组合方法的光伏功率预测[J].电子测量技术,2023,46(21):63-71.
YUAN J H, JIANG W J, LI H Q, et al. Photovoltaic power prediction based on SSA-BiLSTM nonlinear combination method[J]. Electronic Measurement Technology, 2023,46(21):63-71.
- [20] 武松,马永光.基于混合深度网络的电站锅炉 NO_x 排放预测[J].中国测试,2022,48(10):166-174.
WU S, MA Y G. NO_x emission prediction of power plant boiler based on hybrid depth network[J]. China Measurement,2022,48(10):166-174.
- [21] 包斌虎.基于组合模型的超短期风电功率预测方法研究及应用[D].兰州:兰州大学,2023.
BAO B H. Research and application of ultra-short term wind power forecasting method based on combination model[D]. Lanzhou: Lanzhou University,2023.

作者简介

冯俊磊,硕士研究生,主要研究方向为机器学习和时间序列预测。

E-mail:f2514226422@163.com

吕卫东(通信作者),副教授,主要研究方向为机器学习和可靠性理论。

E-mail:2212963672@qq.com