

DOI: 10.13382/j.jemi.B2104894

融合 CEEMDAN 和 ICS-LSTM 的短期风速预测建模*

王 贺¹ 陈蕤峰¹ 熊 敏² 刘素梅¹

(1. 北京林业大学工学院 北京 100083; 2. 美国田纳西大学电气与计算机科学系 诺克斯韦尔 37996)

摘要:为提高风速预测精度,本文从挖掘风速数据可预测性和优化预测模型性能两方面出发,提出一种融合完全经验模态分解(CEEMDAN)和改进的布谷鸟算法优化长短期记忆深度神经网络(ICS-LSTM)的风速预测模型。首先采用 CEEMDAN 降低风速序列的不稳定性,提高其可预测性。其次对分解得到的各子序列建立 LSTM 预测模型,并采用 ICS 优化 LSTM 的关键参数,提高 LSTM 预测模型的回归性能。然后对各个子序列采用最优参数 LSTM 预测模型进行建模预测,最后叠加子序列预测结果得到风速预测结果。经实测数据验证,本文所提模型的平均绝对误差和平均相对误差仅为 0.82 和 0.95,对比研究表明本文所提预测模型的优越性。

关键词: 风速预测; CEEMDAN; LSTM; 融合预测

中图分类号: TM614 **文献标识码:** A **国家标准学科分类代码:** 470.40

Short-term wind speed forecasting modeling integrating CEEMDAN and ICS-LSTM

Wang He¹ Chen Hongfeng¹ Xiong Min² Liu Sumei¹

(1. School of Technology, Beijing Forestry University, Beijing 100083, China; 2. Department of Electrical Engineering and Computer Science, University of Tennessee, Knoxville 37996, USA)

Abstract: In order to improve the accuracy of wind speed prediction, this paper starts from the predictability of mining wind speed data and optimizes the performance of the prediction model, and proposes a prediction model that combines adaptive noise complete empirical mode decomposition (CEEMDAN) and long short-term memory neural network (LSTM). First, CEEMDAN is used to reduce the instability of the wind speed sequence and improve its predictability. Secondly, a LSTM prediction model is established for each sub-sequence obtained by decomposition, and an improved cuckoo search algorithm (ICS) is used to optimize the key parameters of LSTM and improve its regression performance. Then use the optimal parameter LSTM prediction model for each sub-sequence to model and predict, and superimpose to obtain the wind speed prediction result. Verified by actual measurement data, the average absolute error and average relative error of the model proposed in this paper are only 0.82 and 0.95. The comparative study shows that the proposed prediction model is scientific and advanced.

Keywords: wind speed prediction; CEEMDAN; LSTM; combined prediction

0 引言

日益增长的环保需求和化石能源的枯竭使得新能源产业迅速发展,其中风力发电具有零污染、低运行成本等优点。然而风能的时空分布复杂,变化大且具有强不稳定性等特征,这对风能在电网中的高比例渗透和应用带

来阻碍,精准稳定的风速预测被认为是解决这一问题的有效方法^[1]。然而风速的性质增加了风速预测工作的复杂性和困难性,研究人员建立了多种预测模型对风速进行预测。

统计类预测模型是研究人员较早建立的预测模型,常见的有灰色预测模型、马尔柯夫链预测模型和自回归预测模型等。文献[2]为我国台湾地区某风电场建立

GM(1,1)的风速灰色预测模型,文献[3]改进马尔可夫模型用于风速预测,文献[4]采用 ARIMA 跟踪捕捉风能的湍流动力学特征。统计学模型取得一定的预测效果,然而该类模型主要基于统计学方法,以线性模型为拟合基础,在精细化回归风速的非线性和波动性上还有一定的提升空间。

机器学习类模型如支持向量机模型、神经网络(浅层或深层)模型等,通过学习风速历史数据,获得回归风速变化发展的能力。文献[5]建立了反向 BBA 算法优化 SVM 关键参数的风速预测模型。文献[6]采用增强型蜂群算法优化 LSSVM 关键参数来建立风速预测模型,文献[7]建立了 BP 神经网络风速预测模型,文献[8]建立了和文献[9]则建立了深度置信网络(DBN)和 LSTM 的风速预测模型。机器学习类模型对风速的非线性拟合回归取得了较好的效果,预测精度也得到的提升。尤其是 LSTM 模型解决了序列长期依赖问题,在风速预测中具有优势,然而 LSTM 同样无法避免机器学习模型所具有的共性缺点,其关键参数会影响模型的回归能力,如 LSTM 预模型的时间窗宽 T_s 和隐藏层神经元数目 N_n 等参数。时间窗宽 T_s 影响模型训练过程, N_n 则决定模型拟合效果,而人工靠经验调参存在一定局限性,因此采用人工智能算法优化 LSTM 关键参数受到研究人员的重视^[10]。

组合类预测模型的一种建模思路是组合多种预测模型优点建立预测模型^[11],多模型组合的建模思路可以有效避免单一预测模型的预测风险,然而多模型组合的方式却不一定能获得最好的预测效果。另一种被广泛采用的组合预测建模思路则是从先对原始风速序列进行分解处理,降低不稳定性,然后采用统计学模型或机器学习模型进行建模预测。常见的分解处理方法有小波分解^[12]、EMD^[13]和 EEMD^[14]等。几种分解方法中,CEEMDAN 相对来说是一种更为先进的方法,CEEMDAN^[15]算法是近年来提出的一种新方法,改进了 EEMD 算法的缺点,鉴于此,本文对风速数据序列进行处理时采用 CEEMDAN。

综上所述,本文探索融合 CEEMDAN 和 ICS-LSTM 来建立新型风速预测模型。首先采用 CEEMDAN 来处理风速的强不稳定性,提高风速的可预测性,将原有风速序列分解成不同趋势的子序列。其次分别建立各子序列的 LSTM 预测模型,并采用 ICS 对子序列 LSTM 预测模型的关键参数进行优化;然后采用优化后的关键参数预测各子序列并叠加。最后采用模型评判指标分析模型性能。实测数据研究结果表明,本文融合 CEEMDAN 和 ICS-LSTM 的风速预测模型能更好地回归追踪风速变化趋势,取得了较好的预测效果。

1 本文涉及算法

1.1 CEEMDAN

CEEMDAN 由 EEMD 发展而来的,通过采用具有一定标准偏差的高斯白噪声来缓解 EEMD 模态混叠问题。CEEMDAN 的计算可以描述为如下 3 步^[16]。

第 1 步,向待分解序列中加入 n 组白噪声,从而得到包含 $2n$ 个信号的集合,如式(1)所示。

$$\begin{bmatrix} M_1 \\ M_2 \end{bmatrix} = \begin{bmatrix} 1 & 1 \\ -1 & 1 \end{bmatrix} \begin{bmatrix} S \\ N \end{bmatrix} \quad (1)$$

式中: S 为原始信号; N 为加入的白噪声信号。

第 2 步,对新形成的所有分量信号采用 EMD^[17]分解,其中第 i 个分量的第 f_i 个子序列分量表示为 c_{ij} 。

第 3 步,通过式(2)得到最终分解结果。

$$c_j = \frac{1}{2n} \sum_{i=1}^{2n} c_{ij} \quad (2)$$

式中: c_j 为分解后得到的第 j 个子序列。

1.2 改进的布谷鸟搜索算法

布谷鸟算法^[18]是一种新型的群智能搜索算法,布谷鸟算法具有参数数目少、鲁棒性强、通用性好和全局寻优能力突出等多方面综合优势。布谷鸟算法以寻得全局最优鸟窝为目标,采用如式(3)所示的方法进行鸟窝位置更新:

$$x_i^{(t+1)} = x_i^{(t)} + \alpha \oplus L(\lambda) \quad (3)$$

式中: $x_i^{(t)}$ 为第 i 个鸟窝在第 t 代的位置, α 代表步长,一般 α 的值取 1; \oplus 表示点对点乘积; $L(\lambda)$ 为莱维随机搜寻路线, $L(\lambda)$ 遵循莱维分布,即 $L(\lambda) \sim \mu = t^{-\lambda} (1 \leq \lambda \leq 3)$ 。

从位置更新式(3)可以发现,布谷鸟鸟窝位置更新受到搜索步长 α 影响,如对搜索步长 α 进行有效扰动,可以对 CS 的前后期搜索能力进行强化和调整。本文采用引入步长扰动因子的方式进行步长扰动,步长扰动因子公式如式(4)所示,步长扰动因子可以对步长进行动态扰动,使算法搜索前期的步长较大,从而扩大搜索范围,避免陷入局部最优。后期步长较小,则可增加算法的局部探索能力,更精准的获得最优值。

$$m = \frac{1}{\sqrt{2\pi\theta}} e^{-\frac{(-\frac{t}{T})^2}{2\theta^2}} \quad (4)$$

式中: m 表示步长扰动因子, T 为设置的最大迭代次数, t 为当前迭代次数。增加步长扰动后的 CS 的鸟窝路径及位置更新式(3)此时为:

$$x_i^{(t+1)} = x_i^{(t)} + m \oplus L(\lambda) \quad (5)$$

1.3 LSTM

LSTM 在 RNN 的框架基础通过增加遗忘、输入和输出 3 个门限,很好的解决了 RNN 的长期依赖问题,避免

了梯度消失或梯度爆炸。LSTM 的结构如图 1 所示。

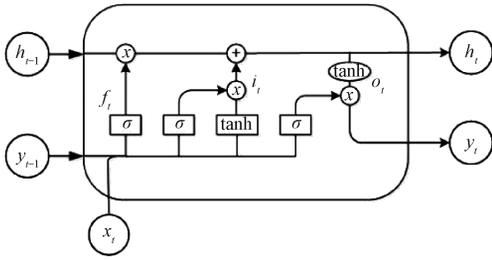


图 1 LSTM 模块内部结构

Fig. 1 LSTM neural network

LSTM 的各门的计算过程如下:

$$f_t = \sigma(\sum W_{sf}x_t + \sum W_{hf}x_{t-1} + \sum W_{of}x_{t-1} + b_f)f_t \quad (6)$$

$$i_t = \sigma(\sum W_{xi}x_t + \sum W_{hi}x_{t-1} + \sum W_{ci}x_{t-1} + b_i) \quad (7)$$

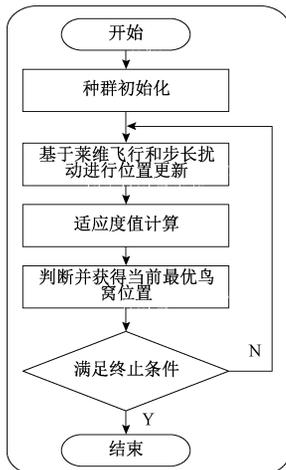
$$o_t = \sigma(\sum W_{xo}x_t + \sum W_{ho}x_{t-1} + \sum W_{co}x_{t-1} + c_o) \quad (8)$$

$$c_t = f_t c_{t-1} + i_t \tanh(\sum W_{xc}x_t + \sum W_{hc}x_{t-1} + b_c) \quad (9)$$

$$h_t = o_t \tanh(c_t) \quad (10)$$

式(6)~(10)中, W 表示各类输入循环权重, b 表示偏置项; i_t 为遗忘门, f_t 为输入门, o_t 为输出门, c_t 为记忆单元的向量值, σ 表示范围在 $(0, 1)$ 之间的 sigmoid 函数。

LSTM 的回归拟合能力受到其网络中关键参数(如时间窗宽和隐藏层神经元数目等)影响,靠经验调参存在一定的局限,所以采用智能算法优化 LSTM 参数受到研究人员的重视。文献[10]和[19]分别 LSTM 预测模型对股票和变压器油中溶解气体浓度预测进行预测,并分别采用遗传算法(GA)和粒子群算法(PSO)优化模型的关键参数。本文探索采用 1.2 节所述的 ICS 来优化 LSTM 风速预测模型的关键参数。



1.4 ICS 优化 LSTM 过程

采取 ICS 对 LSTM 的关键参数进行寻优,流程如下:

1) 种群初始化。设置最大迭代次数 T 、鸟窝数量和概率参数 p_a 。

2) 随机化鸟窝位置。以回归均方根误差最小为适应度函数,计算随机鸟窝位置的适应度,得到目前最优鸟窝位置 x_b^0 。

3) 鸟窝位置更新。依据步长扰动后的鸟窝更新公式(5)更新鸟窝的位置,并计算更新后新一代最优鸟窝。随机产生 $r \in [0, 1]$, 并将 r 与鸟窝主人可发现外来鸟蛋的概率 p_a 比较,如果 $r < p_a$, 则鸟窝位置不发生变化,反之则鸟窝位置再次随机变化,

4) 计算新鸟窝的适应度值并更新确定全局最优鸟窝。

5) 判断算法是否结束。结束则输出最优时间窗宽 T_s 和隐藏层神经元数目 N_n 神经元数目;否则回到 3) 继续搜寻。

2 CEEMDAN-ICS-LSTM 预测模型建模流程

本文探索融合 CEEMDAN 和 ICS 优化 LSTM 的风速预测,该模型建模流程如图 2 所示,具体建模步骤如下:

1) 对原有风速数据序列采用 CEEMDAN 分解,降低风速的间歇性和不确定性,提高风速数据序列的可预测性。

2) 对分解得到的各子序列分别建立一系列的 LSTM 的预测模型,并采用 ICS 优化 LSTM 的关键参数。

3) 采用最优关键参数 LSTM 预测模型对各子序列(IMF)进行预测,并叠加各子序列预测结果。

4) 得到最终预测结果,并根据误差指标公式进行误差计算。

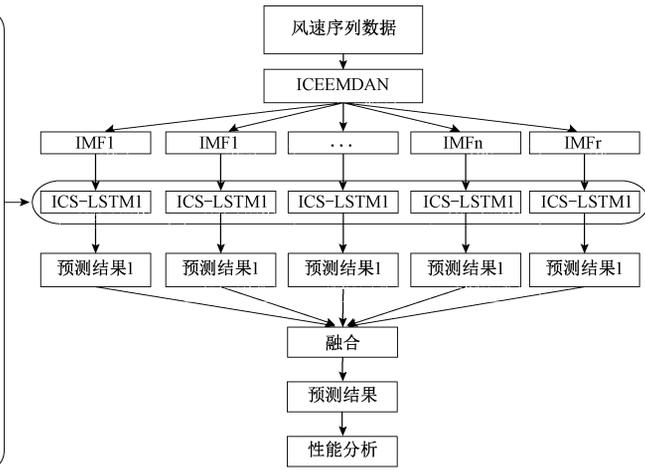


图 2 CEEMDAN-ICS-LSTM 建模流程

Fig. 2 The CEEMDAN-ICS-LSTM modeling flowchart

3 实验设计与结果分析

3.1 模型性能评价指标空

合理有效的对模型预测结果进行定量评价,可以更加客观判断模型性能。本文选取平均绝对误差 σ_{MAE} 、平均相对误差 σ_{MAPE} 和均方根误差 σ_{RMSE} 对模型预测结果进行定量评价,其中平均绝对误差不会出现误差正负相抵消的情况,更直接的反映预测值和实际值之间的真实差距。平均相对误差表征预测实验的可信程度,避免绝对误差只表征大小,却忽略样本自身数值大小不同的弊端。均方根误差表征测量值与真值曲线的拟合程度。用来衡量整体预测样本的准确程度。3 种误差的表达式如下:

1) 平均绝对误差 σ_{MAE}

$$\sigma_{MAE} = \frac{1}{N} \sum_{i=1}^N (p(i) - y(i)) \quad (11)$$

2) 平均相对误差 σ_{MAPE}

$$\sigma_{MAPE} = \frac{1}{N} \sum_{i=1}^n \left| \frac{p(i) - y(i)}{y(i)} \right| \times 100\% \quad (12)$$

3) 均方根误差 σ_{RMSE}

$$\sigma_{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N \left(\frac{p(i) - y(i)}{y(i)} \right)^2} \quad (13)$$

式(11)~(13)中, $y(t)$ 为风速实测值, N 为预测点数量, $p(i)$ 为模型预测结果。

3.2 实验数据选择与处理

为了验证本文提出的模型的有效性和先进性,选择我国西北某风电场 10 m 测风塔的 3 000 个连续实测风速数据作为实验对象,取前 70% 的数据(2 100 个)作为模型的训练数据,后 30% 的数据(900 个)作为模型的测试数据。该测风塔风速采样时间间隔为 5 min。风速数据序列如图 3 所示,对该风速数据序列进行 CEEMDAN 分解,分解结果如图 4 所示。

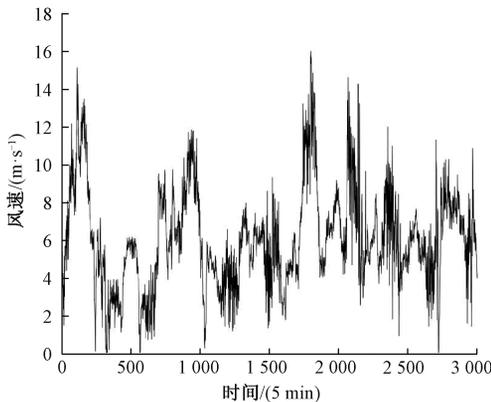


图 3 风速数据序列

Fig. 3 Wind speed data series

3.3 关键参数优化结果

对 3.2 节分解得到的各个子序列分别建立 ICS-LSTM 的预测模型,其中 LSTM 模型为由输入层,一个隐藏层和输出层组成的循环网络,其中隐藏层激活函数采用 tanh 函数,为防止过拟合,迭代次数设为 100。经改进后的布谷鸟算法优化得到的各个子序列 LSTM 预测模型最优超参数如表 1 所示。

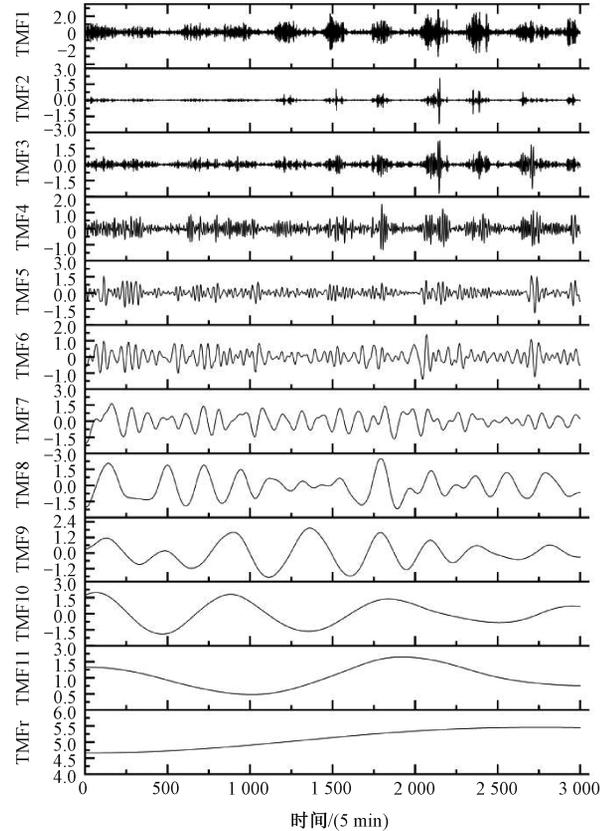


图 4 风速序列 CEEMDAN 分解结果

Fig. 4 Wind speed series decomposition result with CEEMDAN

表 1 各子序列模型的最优关键参数

Table 1 Optimal key parameters of each subsequence model

子序列	最优隐藏层神经元数	最优时间窗宽
IMF1	23	6
IMF2	52	8
IMF3	44	4
IMF4	31	10
IMF5	77	13
IMF6	53	8
IMF7	48	7
IMF8	81	11
IMF9	31	12
IMF10	85	11
IMF11	46	15
IMFr	33	9

3.4 实验结果与模型性能讨论

科学的评判模型性能,离不开多种模型的对比研究,本文同时与如下3种模型进行性能对比:第1种模型,对序列进行 CEEMDAN 分解,然后对 CEEMDAN 分解的各个子序列建立 LSTM 预测模型,并采用 PSO 优化 LSTM 预测预测,称为 CEEMDAN-PSO-LSTM 模型。第2种模型,不对序列进行 CEEMDAN 分解,直接采用 PSO 优化 LSTM 进行建模预测。本文称为 PSO-LSTM 模型。第3种模型,不对序列进行 CEEMDAN 分解,直接采用 ICS 优化 LSTM 进行建模预测。称为 ICS-LSTM 模型。

其中第1种和第2种对比模型中,PSO 参数设置如下:种群规模设置为20,最大迭代次数设置为100,惯性因子设置为1,两个学习因子都设置为0.5。第3种模型中的 ICS 参数设置如下:鸟巢数量等于20,被发现概率 $p_a = 0.25$,迭代次数100次,其中第2种对比模型和第3种对比模型的实验条件相同,都是对未进行数据处理的两种 LSTM 模型进行参数优化,优化过程中的适应度曲线如图5所示。

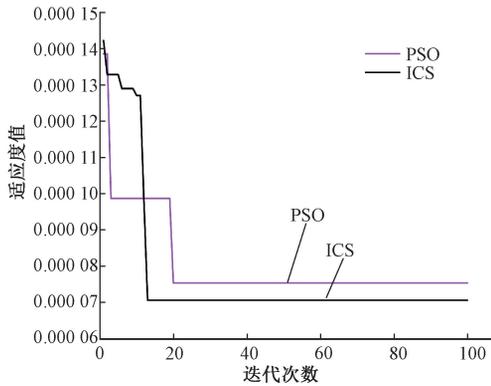


图5 两种算法在优化 LSTM 参数时的适应度值
Fig. 5 The fitness values of the two algorithms in optimizing LSTM parameters

从两种算法的适应度曲线可以发现,ICS 在13步时就获得了最佳适应度,而 PSO 在20步时才获得最佳适应度,ICS 的收敛速度要好于 PSO 算法的收敛速度。从最终收敛的适应度值上也可以发现,ICS 的适应度值要小于 PSO 算法的适应度值,ICS 优化 LSTM 模型对数据的拟合能力要更好。

经过数据处理和分解的两种模型的预测结果如图6所示。未进行数据分解处理的两种模型(PSO-LSTM 和 ICS-LSTM)两种模型的预测结果如图7所示。误差计算结果如表2所示。

结合预测结果图6和7,根据误差指标分析结果表2可以发现:

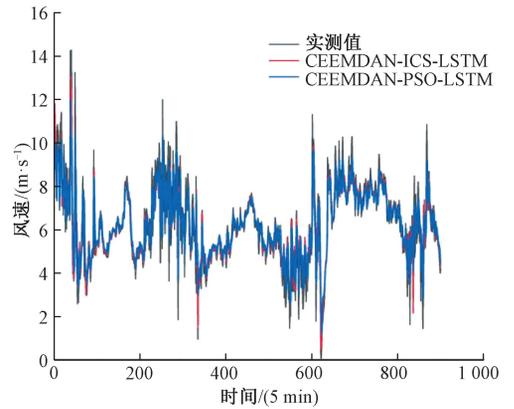


图6 采用 CEEMDAN 的两种模型预测结果
Fig. 6 The result of the forecasting model with CEEMDAN

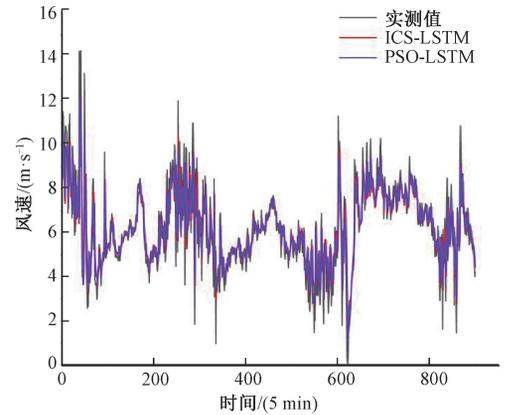


图7 未采用 CEEMDAN 的两种模型预测结果
Fig. 7 The result of the forecasting model without CEEMDAN

表2 4种预测模型误差

Table 2 Errors of four prediction models			
模型	σ_{MAE}	$\sigma_{MAPE}/\%$	σ_{RMSE}
PSO-LSTM	1.89	27.61	2.11
ICS-LSTM	1.73	20.57	1.84
CEEMDAN-PSO-LSTM	0.91	14.53	1.04
CEEMDAN-ICS-LSTM	0.82	9.24	0.95

1) 4种模型都可以进行有效的风速预测,其中 ICS 优化的 LSTM 性能在 CEEMDAN 未分解和分解的情况下都要好于 PSO 优化的 LSTM 性能,说明在优化 LSTM 超参数上,ICS 取得了更好的优化效果。

2) 与未进行序列分解的模型相比,同一种模型在采用 CEEMDAN 分解后进行建模预测精度要好于未对数据进行处理。其中 CEEMDAN-PSO-LSTM 模型相对于 PSO-LSTM 在 σ_{MAE} 、 σ_{MAPE} 和 σ_{RMSE} 三个误差指标上分别提高了 0.98、13.08% 和 1.07。而 CEEMDAN-ICS-LSTM 模型相对于 ICS-LSTM 在 σ_{MAE} 、 σ_{MAPE} 和 σ_{RMSE} 三个误差指标上分

别提高了 0.91、9.338% 和 0.88, 说明了通过 CEEMDAN 分解后在一定程度上提高了风速序列的可预测性。

3) 4 种模型中, 预测效果最好的是本文所提的融合 CEEMDAN 和 ICS-LSTM 的组合预测模型。说明本文模型可以更好的回归拟合风速变化。

4 结 论

针对风速预测困难问题, 本文同时从提高数据的可预测性和提高预测模型的性能两方面着手, 提出一种 CEEMDAN-ICS-LSTM 的风速组合预测模型。一方面采用 CEEMDAN 来降低风速数据的波动性和不稳定性, 提高数据的可预测性。另外一方面采用动态步长因子扰动的布谷鸟算法来优化 LSTM 预测模型的预测性能。模型性能分析表明, 在采用 CEEMDAN 对风速数据系列降低不稳定性后, PSO-LSTM 和 ICS-LSTM 两种预测模型的预测结果都在一定程度上相对于未进行 CEEMDAN 有所提升。在采用 CEEMDAN 分解和未采用 CEEMDAN 分解两种不同的情况下, ICS 优化 LSTM 的预测性能都要好于 PSO 优化 LSTM 的预测性能, 这表明采用 ICS 对 LSTM 预测模型的关键参数进行优化取得了更好的效果。采用实测风电场数据设计的 4 种模型在采用定量误差指标进行评估后证明了本文所提的融合 CEEMDAN 和 ICS-LSTM 的风速预测模型的优越性。

参考文献

- [1] 王慧莹, 吴亮红, 梅盼盼, 等. 果蝇优化广义神经网络的风电功率短期预测 [J]. 电子测量与仪器学报, 2019, 33(6): 177-183.
WANG H Y, WU L H, MEI P P, et al. Fruit fly optimization based generalized regression neural network for wind power short-term prediction [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(6): 177-183.
- [2] HUANG C Y, LIU Y W, TZENG W C, et al. Short term wind speed predictions by using the grey prediction model based forecast method [J]. IEEE Green Technologies Conference, 2011: 1-5.
- [3] XIE K G, LIAO Q L, TAI H M, et al. Non-homogeneous Markov wind speed time series model considering daily and seasonal variation characteristics [J]. IEEE Transactions on Sustainable Energy, 2017, 8(3): 1281-1290.
- [4] SIM S K, MAASS P, LIND P G. Wind speed modeling by nested ARIMA processes [J]. Energies, 2019, 12(1): 69.
- [5] LI Z L, XIA J, LIU A, et al. States prediction for solar power and wind speed using BBA-SVM [J]. IET Renewable Power Generation, 2019, 13(7): 1115-1122.
- [6] TU C S, HONG C M, HUANG H S, et al. Short term wind power prediction based on data regression and enhanced support vector machine [J]. Energies, 2020, 13(23): 6319.
- [7] ZHANG Y G, CHEN B, ZHAO Y, et al. Wind speed prediction of IPSO-BP neural network based on Lorenz disturbance [J]. IEEE Access, 2018, 6: 53168-53179.
- [8] LIN K P, PAI P F, TING Y J. Deep belief networks with genetic algorithms in forecasting wind speed [J]. IEEE Access, 2019, 7: 99244-99253.
- [9] 魏昱洲, 许西宁. 基于 LSTM 长短期记忆网络的超短期风速预测 [J]. 电子测量与仪器学报, 2019, 33(2): 64-71.
WEI Y ZH, XU X N. Ultra-short-term wind speed prediction model using LSTM networks [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(2): 64-71.
- [10] 刘可真, 苟家冀, 骆钊, 等. 基于粒子群优化-长短期记忆网络模型的变压器油中溶解气体浓度预测方法 [J]. 电网技术, 2020, 44(7): 2778-2785.
LIU K ZH, GOU J Q, LUO ZH, et al. Prediction of dissolved gas concentration in transformer oil based on PSO-LSTM model [J]. Power System Technology, 2020, 44(7): 2778-2785.
- [11] HAN Q K, WU H, HU T, et al. Short-term wind speed forecasting based on signal decomposing algorithm and hybrid linear/nonlinear models [J]. Energies, 2018, 11(11): 2976.
- [12] AASIM, SINGH S N, MOHAPATRA A. Repeated wavelet transform based ARIMA model for very short-term wind speed forecasting [J]. Renewable Energy, 2019, 136: 758-768.
- [13] REN Y, SUGANTHAN P N, SRIKANTH N. A comparative study of empirical mode decomposition-based short-term wind speed forecasting methods [J]. IEEE Transactions on Sustainable Energy, 2015, 6(1): 236-244.
- [14] KANG A Q, TAN Q X, YUAN X H, et al. Short-term wind speed prediction using EEMD-LSSVM model [J]. Advances in Meteorology, 2017, 2017: 1-22.
- [15] 耿读艳, 王晨旭, 赵杰, 等. 基于 CEEMDAN-PE 的心冲击信号降噪方法研究 [J]. 仪器仪表学报, 2019, 40(6): 155-161.
GENG D Y, WANG CH X, ZHAO J, et al. Research on BCG signal de-noising method based on CEEMDAN and PE [J]. Chinese Journal of Scientific Instrument, 2019, 40(6): 155-161.

- [16] 张慧, 孟克其劳, 张占强, 等. 基于 CEEMDAN 和 HHT 的谐波检测方法 [J]. 电子测量技术, 2020, 43(6): 83-87.
ZHANG H, MENG K Q L, ZHANG ZH Q, et al. Harmonic detection method based on CEEMDAN and HHT [J]. Electronic Measurement Technology, 2020, 43(6): 83-87.
- [17] 范勇, 王鹏, 张宁超. 基于改进 EMD 与 SOM 神经网络的自动机驱动机构故障诊断研究 [J]. 国外电子测量技术, 2020, 39(8): 5-10.
FAN Y, WANG P, ZHANG N CH. Research on automaton driving mechanism fault diagnosis based on improved EMD and SOM neural network [J]. Foreign Electronic Measurement Technology, 2020, 39(8): 5-10.
- [18] RAKHSHANI H, RAHATI A. Snap-drift cuckoo search: A novel cuckoo search optimization algorithm [J]. Applied Soft Computing, 2017, 52: 771-794.
- [19] 武大硕, 张传雷, 陈佳, 等. 基于遗传算法改进 LSTM 神经网络股指预测分析 [J]. 计算机应用研究, 2020, 37(S1): 86-87, 107.
WU D SH, ZHANG CH L, CHEN J, et al. Improved LSTM neural network stock index forecast analysis based on genetic algorithm [J]. Application Research of Computers, 2020, 37(S1): 86-87, 107.

作者简介



王贺(通信作者), 2009 年于湖南大学获得学士学位。2014 年于武汉大学获得博士学位。现于北京林业大学工学院担任讲师, 主要研究方向为机器学习和信号处理。

E-mail: wanghe@bjfu.edu.cn

Wang He (Corresponding author) received his B. Sc. degree from Hunan University in 2009, and Ph. D. degree from Wuhan University in 2014. Now, he is a lecturer in the School of Engineering, Beijing Forestry University. His main research interests include machine learning and signal processing.



陈燕峰, 2020 年于青岛科技大学获得学士学位, 目前正在北京林业大学攻读硕士学位, 主要研究方向为数据分析和神经网络技术。

E-mail: chenhf_1998@163.com

Chen Hongfeng received his B. Sc. degree from the Qingdao University of Science and Technology in 2020. He is currently a M. Sc. candidate in Beijing Forestry University. His main research interests include data analysis and neural network technology.



熊敏, 2013 年于武汉大学获得学士学位, 2016 年于武汉大学获得硕士学位, 2016 年至 2019 年, 在国网湖北供电公司担任工程师。现于美国田纳西大学诺克斯维尔分校电气工程和计算机科学系攻读博士学位, 主要研究方向为电力系统仿真和暂态稳定

分析。

E-mail: 569860206@qq.com

Xiong Min received his B. Sc. degree from Wuhan University in 2013 and M. Sc. degree from Wuhan University in 2016. He was an engineer in the State Grid Hubei Power Supply Company from 2016 to 2019. Now he is a Ph. D. candidate at the Department of Electrical Engineering and Computer Science, University of Tennessee, Knoxville, USA. His main research interests include power system simulation and transient stability analysis.



刘素梅, 2013 年于华北电力大学获得博士学位。2015 年于华北电力大学博士后出站, 现为北京林业大学副教授, 主要研究方向为新能源电源故障特性及所接电网保护。

E-mail: 191116006@qq.com

Liu Sumei received her Ph. D. degree from North China Electric Power University in 2013 and post-doctoral station from North China Electric Power University in 2015. Now she is an associate professor at Beijing Forestry University. Her main research interests include the fault characteristics of new energy power supply and the protection of connected power grid.