

DOI: 10.19783/j.cnki.pspc.190860

基于 VMD 和 LSTM 的超短期风速预测

王俊¹, 李霞¹, 周昔东², 张凯¹

(1. 重庆交通大学河海学院, 重庆 400074; 2. 重庆交通大学航运与船舶工程学院, 重庆 400074)

摘要: 风速具有非线性、非平稳性以及随机性等特点。为提高超短期风速预测精度, 提出一种基于变分模态分解(VMD)和长短期记忆网络(LSTM)的超短期风速预测新方法。首先利用变分模态方法将风速序列分解成一系列不同的子模态以降低原始数据的复杂度和非平稳性对预测精度的影响。再对得到的风速子模态分别建立 LSTM 模型, 进行超前 1 步风速预测。最后叠加各子模态的预测结果得到最终预测风速。对比分析结果显示, 该模型的预测精度优于其他多种典型风速预测模型, 该模型在超短期风速预测方面表现出较好的性能。

关键词: 超短期风速预测; 变分模态分解; 固有模态分量; 去噪; 长短期记忆网络

Ultra-short-term wind speed prediction based on VMD-LSTM

WANG Jun¹, LI Xia¹, ZHOU Xidong², ZHANG Kai¹

(1. The College of Hohai, Chongqing Jiaotong University, Chongqing 400074, China; 2. The College of Shipping and Ship Engineering, Chongqing Jiaotong University, Chongqing 400074, China)

Abstract: Wind speed has characteristics of non-linearity, non-stationarity and randomness. In order to improve the accuracy of ultra-short-term wind speed prediction, a new method based on VMD and LSTM is proposed. First, the VMD is used to decompose the wind speed sequence into a series of IMF to reduce the complexity and non-stationarity of the original data. Secondly, LSTM models with 1-step ahead wind speed prediction are established for each IMF. Finally, the prediction results of each IMF are superimposed to obtain the final predicted wind speed. The results show that the prediction accuracy of the proposed model is better than other typical wind speed prediction models, and the model has good performance in the prediction of ultra-short wind speed.

This work is supported by Social People's Livelihood Special Fund of Chongqing Municipal Science and Technology Commission (No. cstc2016shmszx30002).

Key words: ultra-short-term wind speed prediction; variational modal decomposition; intrinsic mode function; denoising; LSTM

0 引言

利用可再生能源作为未来能源短缺问题的解决方案的需求日益增长, 许多传统发电系统正被可再生能源系统替代。风能作为世界上最具潜力和实用性、最丰富、最环保的可再生资源之一, 与风能相关的技术需要深入发展^[1-3]。然而, 风力具有间歇性和不确定性, 导致风力发电呈现出不稳定性。

超短期风速的准确预测有助于风电并网的合理调度, 减少因风力变化引起的电压和频率波动, 提

高电网运行的可靠性, 提高风电穿透率^[4-5]。目前, 风速预测方法可分为物理模型、统计方法^[6]。物理模型以数值天气预报模型(NWP)为代表, 采用实时气象条件进行预测, 但由于数值气象模型的复杂性和气象预报数据更新频率较低, 不适用于短期和超短期风速预测^[7]。统计方法通过学习历史风速数据的规律构建数据间的非线性映射关系, 进而实现时序预测。统计方法主要有: 自回归整合移动平均模型(ARIMA)、神经网络法(ANN)、卡尔曼滤波法、支持向量机法(SVM)、深度学习及极限学习机法(ELM)等^[6]。传统的统计方法原理简单, 适应范围广, 但在风速预测方面其精度并不理想, 需要结合其他技术; 对此学术界提出了基于统计方法的混合预测

基金项目: 重庆市科委社会民生专项基金资助(cstc2016shmszx30002)

模型, 对比研究表明混合模型预测效果优于单一预测模型^[8]。文献[9]针对风速时间序列的非线性问题, 建立嵌入 CEEMDAN、VMD 和 AdaBoost 的 RT-ELM 混合模型, 该模型能够较好地捕捉风速时间序列的非线性特征, 获得较高的预测精度。文献[8]利用 CEEMD 和 WT 算法将不稳定的风速序列转化成相对稳定的分量, 再对各分量进行 CNN 预测重构得到最后的预测结果, 提出了 CEEMD-WT-CNN 的短期风速预测模型。文献[5]提出了一种基于 EEMD 和自回归综合移动平均模型的风速预测模型。文献[10]提出了一种基于混合粒子群算法和多分位鲁棒极限学习机的短期风速预测方法, 实现了在不同分位下的高精度短期风速预测。王静和李维德^[7]提出了基于互补型集成经验模态分解和灰狼算法优化支持向量回归机的短期风速预测方法。

本文在现有研究基础上, 基于模态分解算法与机器学习算法的混合策略提出了基于 VMD-LSTM 的混合超短期风速预测模型。变分模态分解在滤除噪声的同时能保留原始信号中的有用成分, 其端点效应可通过镜像延拓得到有效的处理, 分解效果更好^[11]。LSTM 网络弥补了 RNN 存在的梯度消失和梯度爆炸、长期记忆能力不足等问题, 使得循环神经网络能够真正有效地利用长距离的时序信息^[12]。实例分析表明, 该混合模型能有效提高超短期风速预测精度。

1 研究方法

1.1 变分模态分解

K.Dragomiretskiy 和 D.Zosso 在 EMD 的基础上提出的变分模态分解是一种新型复杂信号分解方法。它根据预设的模态数将信号分解为具有不同中心频率的有限带宽, 采用交替方向乘法, 不断更新各模态及其中心频率, 逐步将各模态解调到相应的基频带, 并将各个模态及其相应的中心频率提取出来, 最终得到了各个具有不同中心频率的分量^[13]。

变分模态分解的实质是变分问题, 主要包括变分问题的构造及其求解, 其过程如下^[14-15]:

1) 采用 Hilbert 变换计算每个模态函数 $u_k(t)$ 的解析信号以获得其单边频谱;

2) 通过各模态解析信号与所对应的中心频率 $e^{-j\omega_k t}$ 项混合, 将各模态的频谱调制到基频带;

3) 依据高斯平滑度和梯度平方准则对信号进行解调, 计算其梯度的平方 L_2 范数, 进而得到各个分解模态的带宽。分解后的各模态量都为调幅-调频信号, 其变分约束模型为

$$\min \left\{ \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \quad (1)$$

$$\text{s.t.} \sum_{k=1}^K u_k = f \quad (2)$$

4) 为求取上述变分约束模型的最优解, 引入了二次罚函数 α 和 Lagrange 乘子 λ , 从而将约束性变分问题变为了非约束性变分问题, 得到的拉格朗日函数为

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - [u_k(t)] \right\|_2^2 + \left[\lambda(t), f(t) - \sum_{k=1}^K u_k(t) \right] \quad (3)$$

VMD 中采用了交替方向乘法解决式(2)变分问题, 通过交替更新 u_k^{n+1} 、 ω_k^{n+1} 、 λ_k^{n+1} (n 为迭代次数)求解改进后拉格朗日表达式“鞍点”, 即式(1)中约束变分模型的最优解, 其中解的模态分量新 u_k 及中心频率 ω_k 分别为

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \frac{\hat{u}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (4)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega \left| \hat{u}_k(\omega) \right|^2 d\omega}{\int_0^\infty \left| \hat{u}_k(\omega) \right|^2 d\omega} \quad (5)$$

1.2 长短期记忆网络

长短期记忆网络属于循环神经网络(RNN)的一种优秀变体, 它解决了 RNN 梯度爆炸或梯度消失的问题, 可学习长期依赖信息, 非常适合对时间序列进行分类和预测, 其网络结构如图 1(a)所示。

相对于传统神经网络, RNN 在隐藏层增加了反馈连接。RNN 中隐含层之间结点的互相连接使得隐含层的输出同时进入输出端与下一个时间步骤的隐含层; 利用这种结构, 网络可产生对过去数据的记忆状态, 并建立不同时段数据之间的依赖关系, 因此能更好地处理时间序列问题^[12,16]。但当序列的展开时间过长时, 跨时间步的反向传播扩展有可能导致 RNN 出现梯度消失或爆炸现象, 无法实现可靠的预测。LSTM 通过引入记忆单元取代传统 RNN 的隐含节点, 解决了 RNN 处理过长时间序列时的梯度消失或爆炸问题。RNN 的网络及重复模块结构如图 1(b)所示, 仅包含一个 tanh 函数; 而 LSTM 重复模块由三个 sigmoid 函数和一个 tanh 函数构成,

并引入门限结构：输入门、遗忘门和输出门，这使得 LSTM 能够选择性地记忆新信息或者删除旧信息。

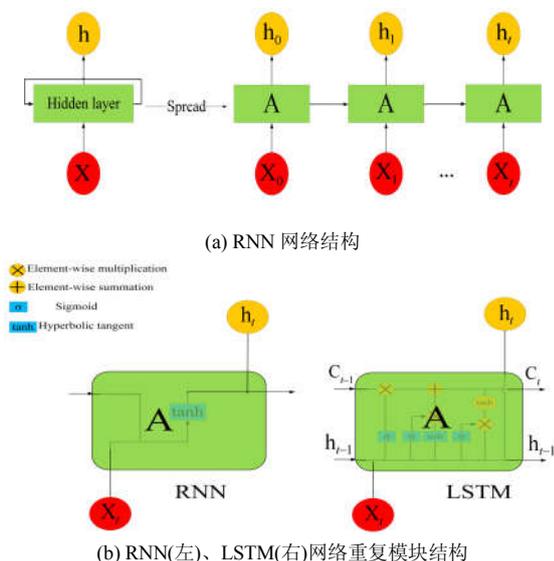


图 1 RNN 和 LSTM 网络结构及重复模块结构
Fig. 1 RNN and LSTM network structure and repeat module structure

2 VMD-LSTM 风速预测模型

2.1 模型构建思路

VMD 和 LSTM 相结合的超短期风速预测步骤如下：

- 1) 首先利用变分模态分解将具有强烈非线性、随机性的原始风速序列分解为一系列平稳的模态分量；
- 2) 对各子模态分量分别建立 LSTM 网络模型；
- 3) 叠加各子模态模型预测值，得到最终的风速预测值。

2.2 数据预处理

时间序列预测要求输入为一定序列长度的数据，需要将风速数据转化为 n 组 m 维的向量。 $m = \text{sequence} + \text{delta}$ ， sequence 为训练数据的序列长度，简称为 seq ， delta 为需要超前预测的序列长度，即使用前 seq 分钟的风速预测后 delta 分钟的风速，风速数据分组构成如图 2 所示。部分学者的研究表明， seq 相同的情况下 delta 增大会使预测精度降低^[6,17-19]；因此本文采用传统的超前 1 步预测，即 $\text{delta}=1$ 。

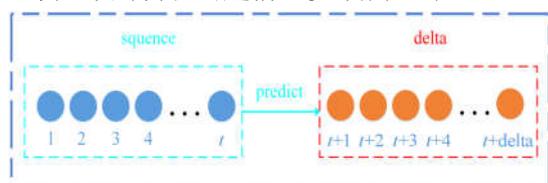


图 2 风速数据分组构成

Fig. 2 Wind speed data grouping and composition

数据集按以下比例进行划分：80%作为训练集用于网络训练，10%作为验证集用于超参数的优化，10%作为测试集用于样本外预测。

2.3 LSTM 网络参数设置

超参数选取对提高 LSTM 网络的预测精度十分重要。本文构建的 LSTM 网络涉及到的超参数主要有：LSTM 层数 L ，隐藏层维数 H ，批大小(batch size) B ，样本训练步长 seq ，随机失活率(dropout) D ，回数(epoch) E 。其中，LSTM 层数依据经验取 $L=2$ ；样本训练步长 seq 则需根据实际情况进行选取；在本文实例分析中所采取的方法为：在单一 LSTM 风速预测模型下，设置 seq 的取值范围为 2~10 进行验证，选择损失和误差较小的步长，试验表明 seq 取值在 2~10 时，预测误差变化较小，考虑到准确率及模型训练耗时长，取 $\text{seq}=4$ 。其他超参数则采用网格搜索算法进行选取，网格搜索算法设置如表 1 所示。

LSTM 网络由两层 LSTM 层和 Dense 全连接层构成，LSTM 层后设置 dropout 层以防止过拟合，训练优化算法采用 Adam。

表 1 LSTM 网络超参数选择情况

Table 1 Experimental settings of deep LSTM hyper-parameters

超参数	网格搜索范围
隐藏层数	[40,80,120,160,200,240]
batch size	[4,8,16,32,64,128]
dropout	[0.1,0.2,0.3,0.4,0.5,0.6]
epoch	[40,80,120,160,200,240]

3 算例分析

3.1 数据来源

数据集来自于科罗拉多山脉的美国国家风速观测站(http://www.nrel.gov/midc/nwtc_m2)。选取 2018 年 12 月 26 日所测数据，每一分钟取一次平均风速，共 1440 条风速数据，风速统计数据见图 3；可以看出风速具有极大的随机性、不稳定性和波动性。

3.2 VMD 分解

VMD 算法涉及到的参数有：模态数 K 、惩罚因子 α 、保真度系数 τ 及收敛停止条件 ϵ 。研究表明 VMD 算法的难点和关键在于如何选定合适的 K 和 α ；而 τ 和 ϵ 通常可取默认值^[20]。模态数 K 太大会产生模态重复或额外的噪声，太小会使模态欠分解； α 主要影响 IMF 的带宽，其值越大，各 IMF 分量的带宽越小，反之，分量的带宽越大^[21]。

本文采用观察中心频率的方法确定 K 值，预设模态数 K 值从小到大取值，当最后一层 IMF 分量的

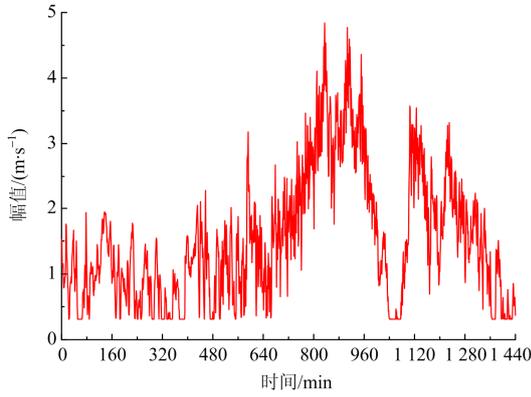


图 3 风速数据

Fig. 3 Wind speed data

中心频率保持相对稳定时,可认为此时 K 取得最佳值^[20]。在不同 K 值的条件下对原始风速序列进行 VMD 分解,得到如表 2 所示的各 IMF 分量中心频率。可以看出,在 $K > 7$ 后最后一层 IMF 分量的中心频率保持相对稳定,因此 $K=8$ 为最佳值。 α 的取值参考文献^[22]的方法,经反复试验得 $\alpha=1\ 000$; $\tau=0.3$,以保证分解的保真度,分解结果如图 4 所示。图 4(b)显示分解结果未出现明显的模态混叠现象,达到了比较理想的结果。

3.3 预测结果

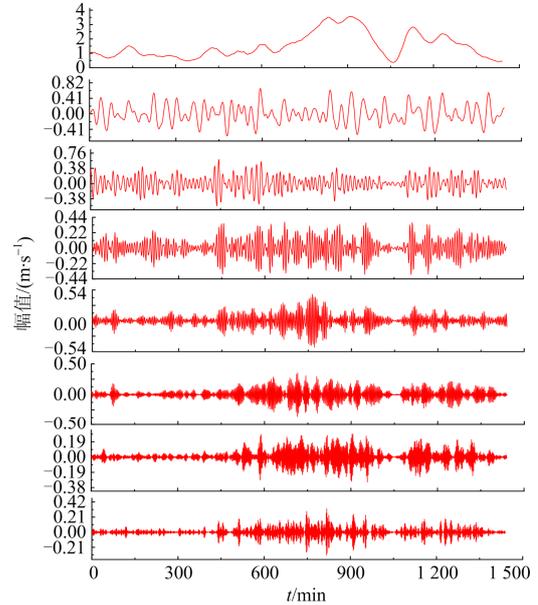
VMD-LSTM 超短期风速预测模型的预测结果如图 5 所示。可以看出,预测模型的预测值与实际值吻合程度高;残差分析结果显示模型的预测残差均匀且随机分布于零基准线的两侧,不存在明显的规律性,说明建模过程中未产生系统误差。故将本文建立的模型用于超短期风速预测是可行的。

4 分析与讨论

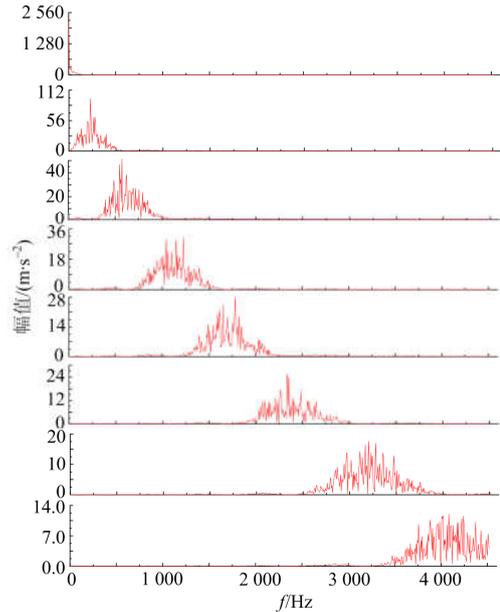
4.1 模型测试集精度分析

将本文的 VMD-LSTM 方法与 WNN、VMD-WNN、VMD-PSO-ELM、VMD-SVM 等其他典型风速预测方法进行对比;所用对比模型相关参数的设置均参考相关文献^[9,23-25]。选用均方根误差 RMSE、绝对平均误差 MAE、平均绝对百分误差 MAPE 对

上述预测模型进行评价。



(a) VMD分解波形



(b) 各模态分量频谱图

图 4 风速序列 VMD 分解结果

Fig. 4 VMD decomposition results of wind speed sequence

表 2 不同 K 值下各 IMF 分量中心频率

Table 2 Frequency of each IMF component center under different K values

K	IMF1	IMF2	IMF3	IMF4	IMF5	IMF6	IMF7	IMF8	IMF9	IMF10
4	0.38	34.83	91.05	181.54						
5	0.37	34.14	87.70	160.81	283.09					
6	0.37	34.07	87.40	159.41	280.93	456.42				
7	0.37	33.93	86.79	156.38	273.20	377.13	507.60			
8	0.37	33.88	86.56	155.34	270.74	373.77	497.01	634.03		
9	0.36	32.17	79.56	128.74	190.57	281.70	379.09	501.90	639.57	
10	0.36	32.15	79.44	128.44	189.89	279.96	366.86	450.97	523.79	659.68

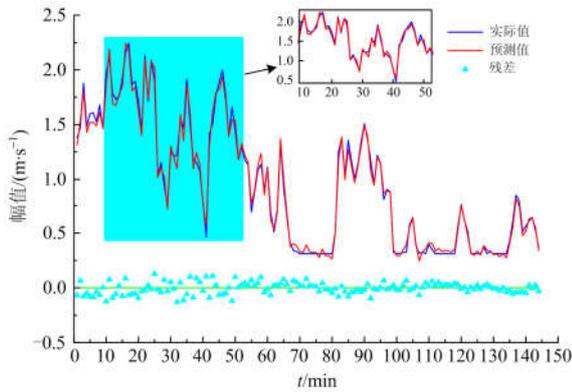
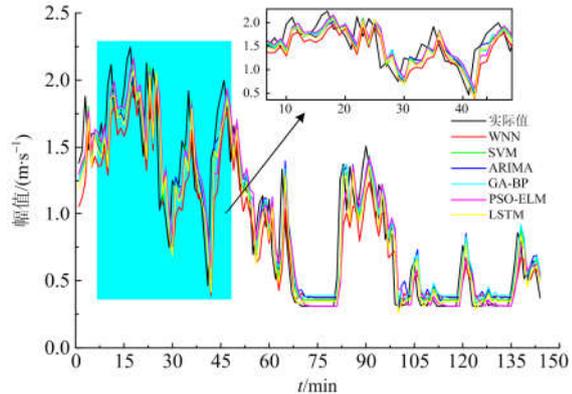


图 5 模型预测结果

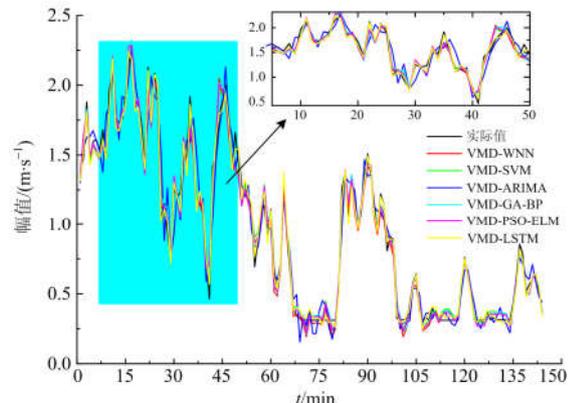
Fig. 5 Prediction results of the model

在测试集上, 各模型预测风速与原始风速的比较如图 6 所示, 它们的评价指标如表 3 所示。

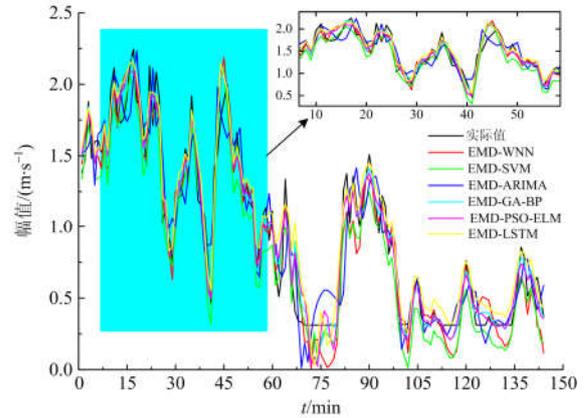
从图 6(a)可以看出, 单一模型的预测曲线与实际风速曲线具有非常接近的形状, 但在对图 6(a)进行放大后可以发现预测曲线相当于将实际风速曲线向右平移了 1 min。事实上, 我们在诸多使用单一模型进行短期风速预测的研究中也发现了这一问题^[23-27], 但未有学者对此进行解释。我们认为, 产生这一问题的原因是单一预测模型无法学习到具有极强随机性、不稳定性的风速序列的内部规律; 又



(a) 单一预测模型



(b) VMD混合模型



(c) EMD混合模型

图 6 不同模型风速预测结果

Fig. 6 Wind speed prediction results of six different models

表 3 不同模型预测误差

Table 3 Prediction errors of different models

预测模型	RMSE/(m·s ⁻¹)	MAPE/%	MAE/(m·s ⁻¹)
VMD-LSTM	0.053	5.638	0.043
VMD-WNN	0.083	8.535	0.064
VMD-GA-BP	0.081	8.526	0.061
VMD-PSO-ELM	0.078	8.101	0.060
VMD-SVM	0.078	8.572	0.060
VMD-ARIMA	0.139	13.023	0.102
EMD-LSTM	0.161	21.673	0.129
EMD-WNN	0.150	19.889	0.120
EMD-GA-BP	0.131	14.652	0.101
EMD-PSO-ELM	0.138	16.033	0.109
EMD-SVM	0.187	23.335	0.158
EMD-ARIMA	0.206	21.731	0.157
LSTM	0.246	18.820	0.171
WNN	0.275	21.918	0.197
GA-BP	0.245	23.376	0.184
PSO-ELM	0.246	19.893	0.175
SVM	0.244	20.779	0.177
ARIMA	0.246	23.223	0.181

因上一时刻的风速与待预测时刻的风速是最接近的, 模型为使目标函数 MSE 的值最小, 直接对上一时刻的实际值进行调整, 将其作为下一时刻的待预测值, 而非通过分析输入数据规律进行非线性映射来实现预测, 此时模型相当于只使用了待预测时刻之前 1 min 的风速, 这也是我们在调整单一模型的 seq 后, 这一现象仍未消失的原因。

由图 6(b)、图 6(c)可看出, VMD 和 EMD 混合模型未出现单一模型的上述问题, 但 EMD 混合模型的预测精度相对于单一模型而言未有明显改善, 且 EMD-LSTM 与 VMD-LSTM 预测效果存在较大差异。经分析, 其原因在于 EMD 高频分量的平稳

性不如 VMD，影响了 LSTM 对高频分量的预测效果，导致 EMD-LSTM 预测效果不佳，这与文献[28]的结论相似。为进一步说明分解结果对 LSTM 预测精度的影响，将 VMD 方法中的参数(K, α)调整为(3, 400)和(4, 1000)后，重新进行分解和测试；结果显示，其 MAPE 分别为 10.341%、11.704%。综上所述，分解结果将对 LSTM 预测精度产生影响，合理选择分解方法和相关参数十分重要。

由表 3 可知，VMD-LSTM 模型的预测精度要明显优于其他模型。其均方根误差 RMSE、绝对平均误差 MAE 和平均绝对百分误差 MAPE 分别为 0.035 m/s、0.043 m/s 和 5.638%，均方根误差 RMSE、绝对平均误差 MAE、平均绝对百分误差 MAPE 分别比单一 LSTM 网络降低了 0.193 m/s、13.182%、0.128 m/s；同时相比于 VMD-WNN、VMD-SVM、VMD-PSO-ELM、VMD-GA-BP、VMD-ARIMA 等模型的预测精度有较大提高。说明 VMD-LSTM 模型可有效提高超短期风速预测的准确度。

4.2 VMD-LSTM 模型外推性能分析

利用滚动预测方法对本文模型的外推性能进行了进一步分析。滚动预测方法的示意图如图 7 所示，这一方法存在“误差累积”的缺陷^[17]，因此更考验模型的外推性及稳健性。

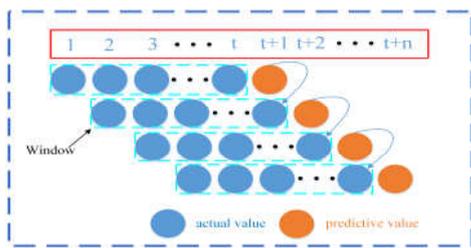


图 7 滚动预测示意图

Fig. 7 Schematic diagram of recursive prediction

由于滚动预测将不断利用预测值来更新模型输入值，为增大预测范围，这里令 $seq=30$ ，即窗口 (Window)大小取 30，其他参数采用前文方法进行确定。为缩短训练时间，同时检验模型在训练数据较少情况下的预测性能，仅利用 2018 年 12 月 26 日后 440 min 实测风速训练模型，对 2018 年 12 月 27 日的 00:00—1:00 时间段进行预测。选择在测试集上表现较好的 VMD-PSO-ELM、VMD-GA-BP-SVM、VMD-WNN 及 VMD-SVM 模型作为对照。5 种模型的预测结果如图 8 所示。可以看出，各模型均存在“误差累积”问题，但 VMD-LSTM 模型的预测效果要优于其他 4 种模型，其 MAPE 值为 14.409%，低于其他模型，这说明 VMD-LSTM 模型具有较强

的稳健性和外推性。

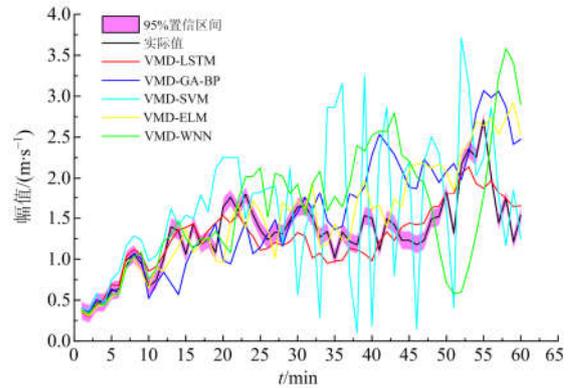


图 8 各模型滚动预测结果

Fig. 8 Results of recursive prediction of various models

5 结论

本文将变分模态分解用于风速序列的平稳化处理，对各 IMF 分量分别建立 LSTM 预测子模型，将各子模型的预测结果叠加求和得到风速预测结果。通过实例分析，得出以下结论：

1) VMD 分解可将具有强非线性、非平稳性及随机性特征的风速时间序列分解为相对稳定的数组 IMF 分量，可增强时间序列的可预报性。

2) 算例研究表明，VMD-LSTM 预测模型充分挖掘了风速序列的特性，有效提高了超短期风速预测的准确度。

3) VMD 混合模型的预测精度优于采用经验模态分解方法的预测模型，说明 VMD 方法对于原始风速序列的分解效果更优。VMD-LSTM 模型可有效预测超短期风速变化，取得了比其他典型超短期风速预测模型更佳的预测效果。

参考文献

[1] MI X, LIU H, LI Y. Wind speed prediction model using singular spectrum analysis, empirical mode decomposition and convolutional support vector machine[J]. Energy Conversion and Management, 2019, 180: 196-205.

[2] MAGDY G, SHABIB G, ELBASET A A, et al. Optimized coordinated control of LFC and SMES to enhance frequency stability of a real multi-source power system considering high renewable energy penetration[J]. Protection and Control of Modern Power Systems, 2018, 3(3): 407-421. DOI: 10.1186/s41601-018-0112-2.

[3] 何廷一, 田鑫萃, 李胜男, 等. 基于蜂群算法改进的 BP 神经网络风电功率预测[J]. 电力科学与技术学报, 2018, 33(4): 22-28.

- HE Tingyi, TIAN Xincui, LI Shengnan, et al. Improved BP neural network based on Artificial Bee Colony algorithm for wind power prediction[J]. *Journal of Electric Power Science and Technology*, 2018, 33(4): 22-28.
- [4] KANI S A P, ARDEHALI M M. Very short-term wind speed prediction: a new artificial neural network—Markov chain model[J]. *Energy Conversion and Management*, 2011, 52(1): 738-745.
- [5] MIN Y, BIN W, LIANG L Z, et al. Wind speed forecasting based on EEMD and ARIMA[C] // 2015 Chinese Automation Congress (CAC), November 27-29, 2015, Wuhan, China: 1299-1302.
- [6] LIU H, MI X, LI Y. Smart multi-step deep learning model for wind speed forecasting based on variational mode decomposition, singular spectrum analysis, LSTM network and ELM[J]. *Energy Conversion and Management*, 2018, 159: 54-64.
- [7] 王静, 李维德. 基于 CEEMD 和 GWO 的超短期风速预测[J]. *电力系统保护与控制*, 2018, 46(9): 69-74.
WANG Jing, LI Weide. Ultra-short-term forecasting of wind speed based on CEEMD and GWO[J]. *Power System Protection and Control*, 2018, 46(9): 69-74.
- [8] 颜宏文, 卢格宇. CEEMD-WT 和 CNN 在短期风速预测中的应用研究[J]. *计算机工程与应用*, 2018, 54(9): 224-230.
YAN Hongwen, LU Geyu. Application research on complete ensemble empirical mode decomposition, wavelet transform and convolutional neural networks in short-term wind speed forecasting[J]. *Computer Engineering and Applications*, 2018, 54(9): 224-230.
- [9] PENG T, ZHOU J, ZHANG C, et al. Multi-step ahead wind speed forecasting using a hybrid model based on two-stage decomposition technique and AdaBoost-extreme learning machine[J]. *Energy Conversion and Management*, 2017, 153: 589-602.
- [10] 鲁迪, 王星华, 贺小平. 基于混合粒子群算法和多分位鲁棒极限学习机的短期风速预测方法[J]. *电力系统保护与控制*, 2019, 47(5): 115-122.
LU Di, WANG Xinghua, HE Xiaoping. Hybrid population particle algorithm and multi-quantile robust extreme learning machine based short-term wind speed forecasting[J]. *Power System Protection and Control*, 2019, 47(5): 115-122.
- [11] 许杏花, 潘庭龙, 吴定会. 基于变分模态分解的风电场风速降噪研究[J]. *系统仿真学报*, 2019, 31(1): 87-93.
XU Xinghua, PAN Tinglong, WU Dinghui. Wind speed noise reduction in wind farm based on variational mode decomposition[J]. *Journal of System Simulation*, 2019, 31(1): 87-93.
- [12] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. *Neural Computation*, 1997, 9(8): 1735-1780.
- [13] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition[J]. *IEEE Transactions on Signal Processing*, 2014, 62(3): 531-544.
- [14] ALI M, KHAN A, REHMAN N U. Hybrid multiscale wind speed forecasting based on variational mode decomposition[J]. *International Transactions on Electrical Energy Systems*, 2018, 28(1): 1-21.
- [15] 陈强伟, 蔡文皓, 牛春光, 等. 基于 VMD 的 APF 谐波检测算法[J]. *电力科学与技术学报*, 2018, 33(1): 120-124.
CHEN Qiangwei, CAI Wenhao, NIU Chunguang, et al. A APF harmonics detection method based on VMD[J]. *Journal of Electric Power Science and Technology*, 2018, 33(1): 120-124.
- [16] LOPEZ E, VALLE C, ALLENDE H, et al. Wind power forecasting based on echo state networks and long short-term memory[J]. *Energies*, 2018, 11(3): 526-536.
- [17] LI Y, SHI H, HAN F, et al. Smart wind speed forecasting approach using various boosting algorithms, big multi-step forecasting strategy[J]. *Renewable Energy*, 2019, 135: 540-553.
- [18] LIU H, MI X, LI Y. Smart deep learning based wind speed prediction model using wavelet packet decomposition, convolutional neural network and convolutional long short term memory network[J]. *Energy Conversion and Management*, 2018, 166: 120-131.
- [19] WANG J, LI Y. Multi-step ahead wind speed prediction based on optimal feature extraction, long short term memory neural network and error correction strategy[J]. *Applied Energy*, 2018, 230: 429-443.
- [20] 杨大为, 冯辅周, 赵永东, 等. VMD 样本熵特征提取方法及其在行星变速箱故障诊断中的应用[J]. *振动与冲击*, 2018, 37(16): 198-205.
YANG Dawei, FENG Fuzhou, HAO Yongdong, et al. A VMD sample entropy feature extraction method and its application in planetary gearbox fault diagnosis[J]. *Journal of Vibration and Shock*, 2018, 37(16): 198-205.
- [21] 陈陈, 李晓明, 杨玲君, 等. 变分模态分解在电力系统谐波检测中的应用[J]. *电力系统保护与控制*, 2018, 46(14): 69-76.
CHEN Chen, LI Xiaoming, YANG Lingjun, et al. Application of variational mode decomposition in power system harmonic detection[J]. *Power System Protection and Control*, 2018, 46(14): 69-76.

- [22] 方军强. 基于变分模态分解的船用齿轮箱故障诊断研究[D]. 武汉: 武汉理工大学, 2017.
FANG Junqiang. Research on fault diagnosis of marine gearbox based on variational mode decomposition[D]. Wuhan: Wuhan University of Technology, 2017.
- [23] MI X, LIU H, LI Y. Wind speed prediction model using singular spectrum analysis, empirical mode decomposition and convolutional support vector machine[J]. Energy Conversion and Management, 2019, 180: 196-205.
- [24] ZHANG C, ZHOU J, LI C, et al. A compound structure of ELM based on feature selection and parameter optimization using hybrid backtracking search algorithm for wind speed forecasting[J]. Energy Conversion & Management, 2017, 143: 360-376.
- [25] SANTHOSH M, VENKAIHAH C, KUMAR D M V. Ensemble empirical mode decomposition based adaptive wavelet neural network method for wind speed prediction[J]. Energy Conversion & Management, 2018, 168: 482-493.
- [26] LI H. Component decomposition to improve precision of short-term wind speed forecasting[C] // 2017 IEEE International Conference on Smart Grid and Smart Cities (ICSGSC), July 23-26, 2017, Singapore, Singapore: 132-136.
- [27] LIU H, MI X, LI Y. Comparison of two new intelligent wind speed forecasting approaches based on wavelet packet decomposition, complete ensemble empirical mode decomposition with adaptive noise and artificial neural networks[J]. Energy Conversion and Management, 2018, 155: 188-200.
- [28] 王韶, 杨江平, 李逢兵, 等. 基于经验模式分解和神经网络的短期风速组合预测[J]. 电力系统保护与控制, 2012, 40(10): 6-11.
WANG Shao, YANG Jiangping, LI Fengbing, et al. Short-term wind speed forecasting based on EMD and ANN[J]. Power System Protection and Control, 2012, 40(10): 6-11.

收稿日期: 2019-07-22; 修回日期: 2019-09-24

作者简介:

王 俊(1997—), 男, 本科, 研究方向为数据挖掘;

E-mail: junw1997@163.com

李 霞(1977—), 女, 通信作者, 博士研究生, 副教授, 研究方向为水电工程设计与研究。E-mail: 154211570@qq.com

(编辑 葛艳娜)