

DOI: 10.19783/j.cnki.pspc.210123

## 基于RR-VMD-LSTM的短期风电功率预测

史加荣<sup>1</sup>, 赵丹梦<sup>1</sup>, 王琳华<sup>1</sup>, 姜天祥<sup>2</sup>

(1. 西安建筑科技大学, 陕西 西安 710055; 2. 陕西省地方电力(集团)有限公司, 陕西 宝鸡 721000)

**摘要:** 准确的风电功率预测有利于电力系统运行、峰值调节、安全分析和节能减耗。提出了一种基于鲁棒回归(Robust Regression, RR)和变分模态分解(Variational Mode Decomposition, VMD)的长短时记忆(Long Short-Term Memory, LSTM)模型的风电功率预测方法。先使用RR处理采集数据的缺失值和异常点。再利用VMD得到风电功率序列以消除噪声并挖掘原始序列的主要特征。最后采用LSTM对每个分解序列的历史时间序列进行学习并完成预测,并通过重构所有序列的预测值获得风电功率的最终结果。使用所提出的方法对华北某一风电场风电功率进行预测,将预测结果与其他模型对比。结果表明,使用RR-VMD-LSTM方法能显著改善预测性能,降低风电功率预测误差。

**关键词:** 风电功率; 短期预测; 鲁棒回归; 变分模态分解; 长短时记忆

### Short-term wind power prediction based on RR-VMD-LSTM

SHI Jiarong<sup>1</sup>, ZHAO Danmeng<sup>1</sup>, WANG Linhua<sup>1</sup>, JIANG Tianxiang<sup>2</sup>

(1. Xi'an University of Architecture and Technology, Xi'an 710055, China;

2. Shaanxi Regional Electric Power Group Co., Ltd., Baoji 721000, China)

**Abstract:** Accurate wind power prediction is beneficial for power system operation, peak regulation, safety analysis and consumption reduction. A wind power prediction method is proposed based on Long Short-Term Memory (LSTM) combining Robust Regression (RR) and Variational Mode Decomposition (VMD). The RR method is first used to process the missing values and abnormal points of the collected data. Then VMD is proposed to decompose the wind power sequence to eliminate noise and inherit the main characteristics of the original sequence. Finally, LSTM is employed to learn the historical time series of each decomposition sequence and complete the prediction, and all prediction results are integrated to obtain the final prediction of wind power. The proposed method is applied in the wind power prediction of one farm in North China, and the prediction results are compared with other models. The results show that the RR-VMD-LSTM method can significantly improve the prediction performance and reduce the wind power prediction error.

This work is supported by the "the 13th Five-Year" National Key Research and Development Program of China (No. 2018YFB1502902) and the Natural Science Foundation of Shaanxi Province (No. 2021JM-378).

**Key words:** wind power; short-term prediction; robust regression; variational mode decomposition; long short-term memory

## 0 引言

随着化石能源的逐渐枯竭和环境污染的日益严重,新能源的开发、利用和推广已成为必然趋势。风能作为一种丰富的环境友好型新能源,在最近几十年中发展迅速。2020年世界能源统计年鉴显示风力发电量较上一年增长1.3%,中国占90%以上<sup>[1]</sup>。

**基金项目:** “十三五”国家重点研发计划项目资助(2018YFB1502902); 陕西省自然科学基金项目资助(2021JM-378)

目前中国对风能发电的运用越来越广泛,但风能的随机性、间歇性和不确定性会对电网的安全稳定运行产生不利影响<sup>[2-3]</sup>。准确的风电功率预测有利于风电系统的运行、调峰、安全分析和能源交易<sup>[4-6]</sup>。

原始风电功率数据往往存在缺、漏、错的现象,影响风电功率的预测精度。通常采用人工剔除异常数据,但由于人工操作的低效率和低精度,无法保证数据的精确性和一致性。空间插值法、线性回归和自回归滑动平均等方法虽然能够推测缺失值,但无法处理大量缺失数据<sup>[7-8]</sup>。鲁棒回归(Robust Regression, RR)是机器学习和数据挖掘中的重要工

具, 能够有效地去除数据中的噪声影响, 近年来已经被应用到诸多领域中<sup>[9-10]</sup>。本文使用这一方法处理原始风电功率数据的异常点以提升预测精度, 同时获得发电功率与风速的函数关系。

风电功率序列通常是非平稳的, 故直接对原始风电功率序列进行预测可能导致误差较大<sup>[11-12]</sup>。对风电数据按频率进行分解, 可以降低数据复杂度且有效提高预测精度<sup>[13-14]</sup>。比较常用的分解方法有快速傅里叶变换(Fast Fourier Transform, FFT)、小波变换(Wavelet Transform, WT)、经验模态分解(Empirical Mode Decomposition, EMD)等<sup>[15-16]</sup>。FFT 在全局上分解信号, 未考虑时频的局部特性; WT 能够从多尺度分解原始序列, 但需要人工设置参数, 未从根本上解决 FFT 的局限性; 与 FFT 和 WT 相比, EMD 能自主获取输入数据特性, 具有自适应性和多分辨率<sup>[17]</sup>, 但它会产生模态混叠现象<sup>[18-19]</sup>。文献[20]提出了变分模态分解(Variational Mode Decomposition, VMD), 这种新颖的分解方法能够自己调节分解出模态个数, 从而解决了 EMD 模态混叠问题。作为一种自适应的、完全非递归的分解方法, VMD 对噪声有更强的鲁棒性, 并且通过对收敛条件的合理控制, 使得分量个数较小、分解效果较好<sup>[13]</sup>。文献[21]将 VMD 用于短期光伏功率预测, 验证了该方法的有效性。鉴于 VMD 的以上优点, 本文将其作为风电功率的分解方法。

风电功率预测方法主要有 3 种: 物理模型、统计模型和机器学习模型。物理模型适应于特定地区的长期风速预测<sup>[22]</sup>; 统计模型具有简单的模型结构、快速的计算速度和良好的解释能力, 但是预测精度随着时间的增加而降低; 机器学习模型具有强大的非线性映射功能, 因此具有较好的性能<sup>[23-24]</sup>。文献[25-27]对比了长短时记忆(Long Short-Term Memory, LSTM)模型和其他预测模型, 结果表明 LSTM 网络的短期预测和长期预测都优于传统的机器学习预测模型。由于 LSTM 的精确程度依赖于输入数据的质量, 因此合理的数据处理和分解能够提升 LSTM 的学习效果。

本文采用 RR-VMD-LSTM 组合预测模型, 从而进一步提升预测性能。先利用 RR 修正采集的原始风电功率数据, 再使用 VMD 将预处理后的风电功率分解为不同模态的分量, 最后对每个模态建立 LSTM 预测模型。

## 1 模型原理

### 1.1 鲁棒回归

RR 能够有效地恢复数据中的重要成分, 减轻

异常数据影响, 从而提高抗噪声性能<sup>[28]</sup>。对于变速风力涡轮机, 其产生的输出机械功率通常表示为风速的三次函数<sup>[29]</sup>。为此, 本文建立如式(1)的 RR 模型。

$$y = ax^3 + b + \varepsilon, \varepsilon \sim \text{Lap}(0, \sigma) \quad (1)$$

式中:  $x$  表示风速;  $y$  表示相应的输出功率; 噪声  $\varepsilon$  服从均值为 0、尺度参数为  $\sigma$  的拉普拉斯分布;  $a$  和  $b$  为待求参数。

给定  $n$  组风速与功率观测值  $\{(x_i, y_i)\}_{i=1}^n$ , 根据极大似然估计法得到如式(2)的优化模型。

$$\min_{a,b} \sum_{i=1}^n |y_i - (ax_i^3 + b)| \quad (2)$$

记

$$\mathbf{x} = (x_1, x_2, \dots, x_n)^T, \mathbf{y} = (y_1, y_2, \dots, y_n)^T, \\ \boldsymbol{\theta} = (a, b)^T, \mathbf{X} = \begin{pmatrix} x_1^3 & x_2^3 & \dots & x_n^3 \\ 1 & 1 & \dots & 1 \end{pmatrix}^T,$$

则优化问题(2)变为

$$\min_{\boldsymbol{\theta}} \|\mathbf{y} - \mathbf{X}\boldsymbol{\theta}\|_1 \quad (3)$$

式中,  $\|\cdot\|_1$  表示向量的  $l_1$  范数。通过引入辅助变量  $\mathbf{z}$ , 上述优化模型等价于式(4)。

$$\min_{\boldsymbol{\theta}, \mathbf{z}} \|\mathbf{z}\|_1, \quad \text{s.t. } \mathbf{z} = \mathbf{y} - \mathbf{X}\boldsymbol{\theta} \quad (4)$$

使用交替方向乘子法(Alternating Direction Method of Multipliers, ADMM)求解  $l_1$  最小化问题<sup>[9]</sup>。为此, 先构造增广拉格朗日函数, 如式(5)所示。

$$L_1(\boldsymbol{\theta}, \mathbf{z}, \mathbf{u}) = \|\mathbf{z}\|_1 + \mathbf{u}^T(\mathbf{z} - \mathbf{y} + \mathbf{X}\boldsymbol{\theta}) + \frac{1}{2}\rho\|\mathbf{z} - \mathbf{y} + \mathbf{X}\boldsymbol{\theta}\|_2^2 \quad (5)$$

式中:  $\|\cdot\|_2$  表示  $l_2$  范数;  $\mathbf{u}$  表示乘子向量;  $\rho$  为惩罚系数。于是式(5)等价于式(6)。

$$L_1(\boldsymbol{\theta}, \mathbf{z}, \mathbf{u}) = \|\mathbf{z}\|_1 + \frac{1}{2}\rho\|\mathbf{z} - \mathbf{y} + \mathbf{X}\boldsymbol{\theta} + \mathbf{u}/\rho\|_2^2 - \frac{1}{2\rho}\|\mathbf{u}\|_2^2 \quad (6)$$

求解优化问题(4)的迭代更新算法如下。

步骤 1 初始化  $\mathbf{z}, \mathbf{u}, \rho, \boldsymbol{\theta}_0, \varepsilon$ ;

步骤 2  $\boldsymbol{\theta} := (\mathbf{X}\mathbf{X}^T)^{-1}\mathbf{X}(\mathbf{y} - \mathbf{z} - \mathbf{u})$ ;

步骤 3  $\mathbf{z} := \max((\mathbf{y} - \mathbf{X}\boldsymbol{\theta} - \mathbf{u}) - \mathbf{1}, \mathbf{0}) + \min((\mathbf{y} - \mathbf{X}\boldsymbol{\theta} - \mathbf{u}) + \mathbf{1}, \mathbf{0})$ ;

步骤 4  $\mathbf{u} := \mathbf{u} + (\mathbf{z} - \mathbf{y} + \mathbf{X}\boldsymbol{\theta})$ ;

步骤 5 如果  $\|\boldsymbol{\theta} - \boldsymbol{\theta}_0\|_2 \leq \varepsilon$ , 迭代终止, 输出  $\boldsymbol{\theta}$ ;

否则,  $\boldsymbol{\theta}_0 := \boldsymbol{\theta}$ , 转步骤 2。

为了得到更加合理的回归模型, 可以考虑分段策略。将  $x$  的取值区间  $[\tilde{x}_{\min}, \tilde{x}_{\max}]$  分成若干个子区间, 当  $x$  在第  $l$  个区间时, RR 模型为

$$y = a_l x^3 + b_l + \varepsilon_l, \varepsilon_l \sim \text{Lap}(0, \sigma_l) \quad (7)$$

类似地使用 ADMM 方法求解最优参数  $a_i$  和  $b_i$ 。

为了检验可能的异常点, 将  $x$  的取值区间分成  $p$  个等长度的小区间。

$$[\tilde{x}_0, \tilde{x}_1], [\tilde{x}_1, \tilde{x}_2], \dots, [\tilde{x}_{p-1}, \tilde{x}_p],$$

其中:  $\tilde{x}_0 = \tilde{x}_{\min}$ ;  $\tilde{x}_p = \tilde{x}_{\max}$ 。每个小区间的长度为

$$h = (\tilde{x}_{\max} - \tilde{x}_{\min}) / p \quad (8)$$

最终构造  $p$  个集合

$$I_q = \{y_i | x_i \in [\tilde{x}_q - h/2, \tilde{x}_q + h/2]\}, q = 1, 2, \dots, p$$

计算  $I_q$  的  $p_1$  分位数  $y_{qp1}$  和  $p_2$  分位数  $y_{qp2}$ , 此处  $p_1 < p_2$ 。分别将  $y_{qp1}$  和  $y_{qp2}$  作为所选置信区间的下限和上限。对于

$$y_{i^*} \in \{y_i \in I_q | y_i < y_{qp1} \text{ 或 } y_i > y_{qp2}\}$$

按 RR 模型重新计算, 即  $y_{i^*} := \alpha x_{i^*}^3 + b$ 。

## 1.2 变分模态分解

VMD 是一种非递归的方法, 将时间序列  $y(t)$  分解为  $K$  个模态  $\{u_k(t)\}_{k=1}^K$ 。每个模态  $u_k(t)$  有一个中心频率  $\omega_k$ , VMD 的目标是使每个模态的估计带宽的总和最小<sup>[18]</sup>。为了估计所有模态的带宽, 建立如下变分优化模型:

$$\begin{aligned} \min_{\{u_k\}, \{\omega_k\}} & \sum_{k=1}^K \left\| \partial_t [(\delta(t) + j/(\pi t)) * u_k(t)] e^{-j\omega_k t} \right\|_2^2 \\ \text{s.t.} & \sum_{k=1}^K u_k(t) = y(t) \end{aligned} \quad (9)$$

式中:  $*$  表示卷积;  $\{u_k\} = \{u_k(t)\}_{k=1}^K$  表示分解的模态信号集合;  $\{\omega_k\} = \{\omega_k\}_{k=1}^K$  表示中心频率的集合;  $\delta(t)$  是狄拉克函数,  $(\delta(t) + j/(\pi t)) * u_k(t)$  为  $u_k(t)$  的希尔伯特变换,  $\partial_t$  表示关于  $t$  的偏导算子,  $j^2 = -1$ 。

为了求解上述最优化问题, 先构造增广拉格朗日函数, 如式(10)所示。

$$\begin{aligned} L_2(\{u_k\}, \{\omega_k\}, \lambda) = & \alpha \sum_{k=1}^K \left\| \partial_t [(\delta(t) + j/(\pi t)) * u_k(t)] e^{-j\omega_k t} \right\|_2^2 + \\ & \left\| y(t) - \sum_{k=1}^K u_k(t) \right\|_2^2 + \left\langle \lambda(t), y(t) - \sum_{k=1}^K u_k(t) \right\rangle \end{aligned} \quad (10)$$

式中:  $\alpha > 0$ ;  $\langle \cdot, \cdot \rangle$  为函数内积算子。

采用 ADMM 来交替更新  $\{u_k\}$ 、 $\{\omega_k\}$  和  $\lambda$ 。用  $\hat{y}(\omega)$ 、 $\hat{u}_k(\omega)$  和  $\hat{\lambda}(\omega)$  分别表示  $y(t)$ 、 $u_k(t)$  和  $\lambda(t)$  的傅里叶变换。当  $\{u_k\}$ 、 $\{\omega_k\}$  和  $\lambda(t)$  给定时, 先更新  $u_k(t)$  的傅里叶变换, 如式(11)所示。

$$\hat{u}_k(\omega) := \frac{\hat{y}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \hat{\lambda}(\omega) / 2}{1 + 2\alpha(\omega - \omega_k)^2} \quad (11)$$

再更新中心频率:

$$\omega_k := \frac{\int_0^{+\infty} \omega |\hat{u}_k(\omega)|^2 d\omega}{\int_0^{+\infty} |\hat{u}_k(\omega)|^2 d\omega} \quad (12)$$

最后更新拉格朗日乘子的傅里叶变换。

$$\hat{\lambda}(\omega) := \hat{\lambda}(\omega) + \tau \left( \hat{y}(\omega) - \sum_{k=1}^K \hat{u}_k(\omega) \right) \quad (13)$$

式中, 步长  $\tau > 0$ 。

变分模态分解的迭代过程主要包括以下 5 个步骤。

步骤 1 给定时间序列  $y(t)$ , 初始化模式  $\{u_k\}$ 、中心频率  $\{\omega_k\}$  和拉格朗日乘子  $\lambda(t)$ ;

步骤 2 根据式(11)更新  $\hat{u}_k(\omega)$ ,  $k = 1, 2, \dots, K$ ;

步骤 3 根据式(12)更新  $\omega_k$ ,  $k = 1, 2, \dots, K$ ;

步骤 4 根据式(13)更新  $\hat{\lambda}$ ;

步骤 5 如果满足停止条件, 则终止迭代, 输出  $\{\hat{u}_k(\omega)\}_{k=1}^K$ ; 否则, 转步骤 2。

对于上述迭代过程输出的  $\hat{u}_k(\omega)$ , 执行傅里叶反变换得到  $u_k(t)$ 。

## 1.3 长短期记忆模型

LSTM 是传统循环神经网络的改进, 它在处理短期和长期依赖关系的问题上更加稳健。LSTM 主要的贡献是提出了三个门来控制其历史信息的记忆, 即输入门、遗忘门和输出门<sup>[30-31]</sup>。假设输入序列为  $x_t$ , 输出序列为  $y_t$ , 计算过程如图 1 所示。

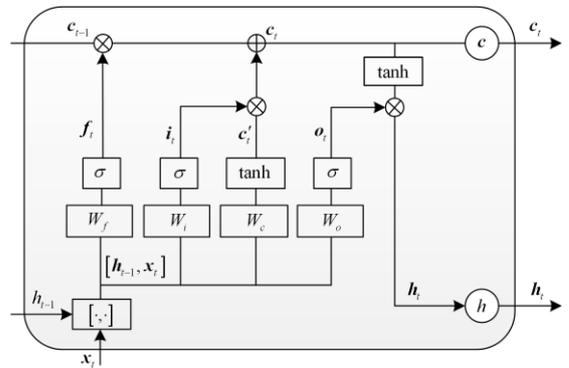


图 1 LSTM 网络结构图

Fig. 1 Structure diagram of LSTM network

在图 1 中,  $h_t$  为时刻  $t$  的隐藏层向量,  $c_t$  为时刻  $t$  的元胞状态,  $W_f$ 、 $W_i$ 、 $W_c$  和  $W_o$  分别为时刻  $t$  的遗忘门、输入门、元胞状态和输出门的权值矩阵,  $\sigma$  为 Sigmoid 激活函数。输入门  $i_t$ 、遗忘门  $f_t$  和输出门  $o_t$  的计算公式为

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (14)$$

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (15)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (16)$$

式中,  $b_i$ 、 $b_f$  和  $b_o$  分别为 3 个门的偏置。

在时刻  $t$ , 元胞状态的更新公式为

$$c_t = f_t \square c_{t-1} + i_t \square c'_t \quad (17)$$

式中, “ $\square$ ” 为 Hadamard 积。

$$c'_t = \sigma(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (18)$$

式中,  $b_c$  为偏置项。最后更新隐藏层向量:

$$h_t = o_t \square \varphi(c_t) \quad (19)$$

式中,  $\varphi$  为  $\tanh$  激活函数。于是有

$$y_t \approx \sigma(W_y \cdot h_t + b_y) \quad (20)$$

式中:  $W_y$  为可调权重矩阵;  $b_y$  为偏置项。

## 2 RR-VMD-LSTM 短期风电功率预测模型构建

### 2.1 RR-VMD-LSTM 模型

由于采集的原始风电功率异常点的数据规模较大且部分预测的功率存在负值, 若直接采用原始功率数据进行预测, 可能导致误差偏大。因此, 为了提高预测的准确性, 采用 RR 处理原始数据的异常值, 以提升数据质量。

由于风电功率具有随机波动性, 直接使用历史风电功率数据进行预测会影响风电功率预测效果。为了进一步提升预测精度, 采用 VMD 将不平稳的风电功率序列分解为几个较平稳的序列, 从而降低预测误差。

对于分解后的每个序列, 将其分成训练集和测试集, 采用 LSTM 在训练集上进行训练, 在测试集上进行预测, 叠加序列的预测值, 得到最终预测结果。本文构建了基于 RR-VMD-LSTM 的短期风电功率预测模型, 主要分为 5 个步骤。

步骤 1 采集风电场风速和风电功率数据, 分析数据质量, 利用 RR 方法补全缺失数据, 并处理异常点;

步骤 2 利用 VMD 获得预处理后的风电功率序列, 得到  $K$  个模态分量;

步骤 3 针对每个模态分量构建 LSTM 进行训练, 并对各个模态分量进行预测;

步骤 4 将各个模态分量预测结果叠加, 重构数据得到某时刻总的风电功率预测结果;

步骤 5 对得到的风电功率预测值进行误差分析, 通过误差评价指标与其他方法进行比较, 并分

析模型性能。

图 2 给出了 RR-VMD-LSTM 组合预测方法的流程。其中, IMF(Intrinsic Mode Functions)为本征模函数, 即对应  $\{u_k\}$ 。

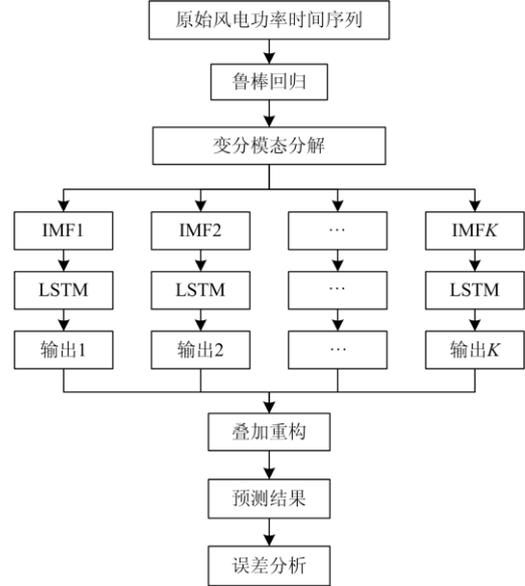


图 2 基于 RR-VMD-LSTM 的短期风电功率预测流程

Fig. 2 Flowchart of short-term wind power prediction based on RR-VMD-LSTM

### 2.2 评价指标

由于平均绝对误差(Mean Absolute Error, MAE)、均方根误差(Root Mean Square Error, RMSE)和平均绝对百分误差(Mean Absolute Percentage Error, MAPE)能有效评价预测性能<sup>[32-33]</sup>, 因此选取这三个标准来评估测试中模型的优劣, 其计算公式为

$$MAE = \frac{1}{n-m} \sum_{i=m+1}^n |y_i - \hat{y}_i| \quad (21)$$

$$RMSE = \sqrt{\frac{1}{n-m} \sum_{i=m+1}^n (y_i - \hat{y}_i)^2} \quad (22)$$

$$MAPE = \frac{1}{n-m} \sum_{i=m+1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (23)$$

式中:  $n$  为风电功率总采样数;  $m$  为训练集样本数量;  $y_i$  为风电功率实际值;  $\hat{y}_i$  为预测值。

## 3 实例验证

采用华北某一风电场 2018 年 7 月的 8 636 条风速和风电功率数据进行研究, 采样时间间隔为 5 min。本节通过对采集的真实数据集进行仿真分析, 通过 3 个模型评估指标和 11 个比较模型来验证所提模型的有效性和稳定性。

### 3.1 基于 RR 的风电功率分析结果

在进行算例分析时, 发现采集的原始数据异常点数量较大, 高于 5%, 使用传统的去除法、插值法、均值替换法处理原始数据的结果并不理想。本文考虑使用 RR 对原始数据异常点进行处理。

所采集的数据在风速大于 2.15 m/s 时风电装机可以发电。根据图 3 的原始风电功率时间序列, 发现在风速大于 2.15 m/s 时, 发电功率存在负值和零值, 将这些点视作异常点。据统计, 采集的风电功率数据具有 653 个零值和 52 个负值。在进行数据处理时, 首先采用 RR 的方式确定风速与风电功率之间的关系, 为了更准确拟合两者之间的关系, 按照风速大小将数据分成 [2.15, 8]、[8, 10]、[10, 12] 3 个子区间, 在每个区间上采用 RR 得到回归方程。之后, 将风速序列所在的区间分成若干个子区间, 第  $q$  个子区间的中心为  $2.1+qh/2$ 。较小的区间长度  $h$  能提升精确度, 但可能会导致子区间包含的点数太少。综合考量选取  $h=0.2$ 。置  $p_1=0.05$ ,  $p_2=0.95$ , 这意味着选取风电功率前后 5% 的数值作为上下限。针对上下限之外的点, 根据其风速值将其代入回归方程中, 重新确定风电功率, 处理后的结果如图 4 所示。

比较图 3 和图 4, 可以看出: 处理后的风电序列有效解决了数据缺失和数据异常的问题, 利用 RR 方法对风电功率数据进行处理, 更有益于后续的预测分析, 提高预测精度。

### 3.2 基于 VMD 的风电功率分解结果

风电功率具有间歇性、不平稳性, 为了消除噪声并进一步挖掘原始数据的主要特征, 利用 VMD 将数据进行分解, 这能够在降低输入序列复杂度的同时提升预测精度。图 5 为 RR 处理后的风电功率序列分解结果。

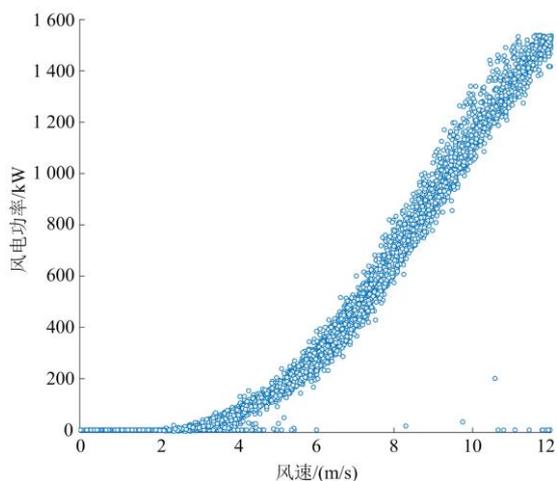


图 3 原始风速和风电功率散点图

Fig. 3 Scatter plot of original wind speed and wind power

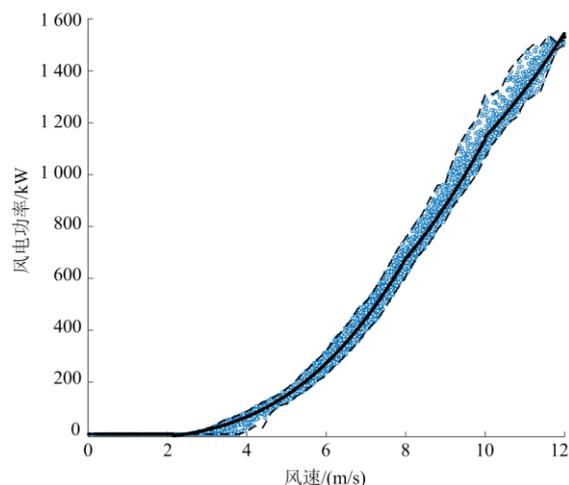


图 4 RR 处理后风速和风电功率散点图

Fig. 4 Scatter plot of wind speed and wind power after RR processing

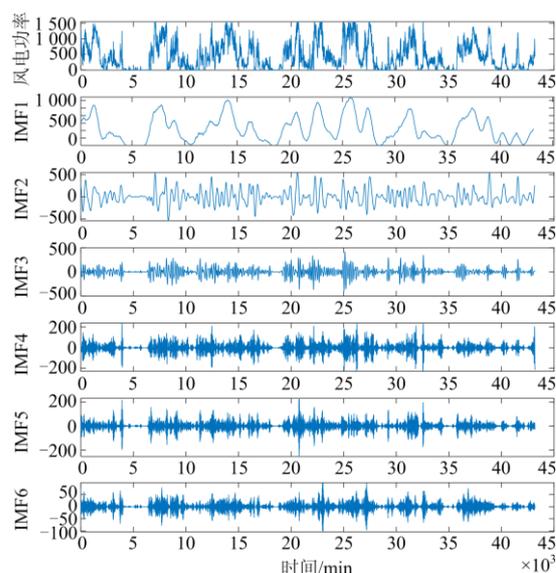


图 5 VMD 实验结果

Fig. 5 Experimental results of VMD

在图 5 中, 将预处理后的数据分解为 6 个模态, 所得到的 IMF 分量与风功率序列相比较为平稳。其中, 最低频率的信号 IMF1 反映了原始序列的变化趋势, 最高频率的信号 IMF6 反映了局部波动率的趋势, 分解后的每个模态既保持了原始风电功率序列的特征又抑制了模态混叠。

### 3.3 基于 RR-VMD-LSTM 的模型预测结果

根据每个模态自身的规律建立 LSTM 模型分别进行预测, 然后将其累加得到最终结果。为了提升模型的准确性, 将采集数据进行预处理, 选取前 90% 用于训练, 后 10% 用于测试。在 LSTM 中, 设置迭

代次数为 250, 初始学习率为 0.005, 在 125 轮训练后通过乘以因子 0.2 来降低学习率, 预测结果如图 6 所示。

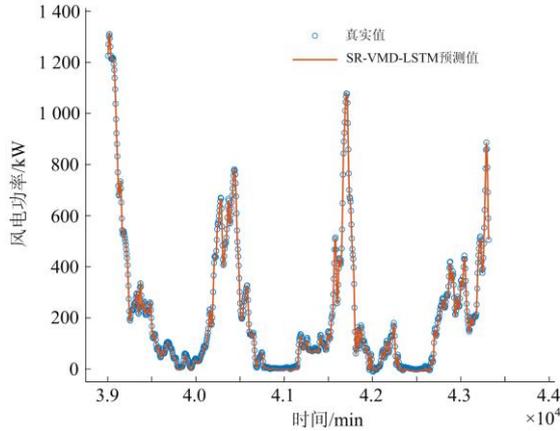


图 6 RR-VMD-LSTM 预测结果

Fig. 6 RR-VMD-LSTM prediction results

从图 6 可以看出, RR-VMD-LSTM 预测结果接近实际值, 该模型的 MAE、RMSE 和 MAPE 分别为 4.64 kW、4.89 kW 和 17.96%。预测结果说明, LSTM 能够有效利用历史信息, 预测效果较好。

### 3.4 预测结果分析

为了进一步验证 RR-VMD-LSTM 的算法性能, 将其与其他 11 个流行的预测模型的结果进行比较。这 11 个模型包括反向传播神经网络(BP)、LSTM、WT-LSTM、EMD-LSTM、VMD-BP、VMD-LSTM、RR-BP、RR-LSTM、RR-WT-LSTM、RR-EMD-LSTM 和 RR-VMD-BP。12 个预测模型的误差评估结果如表 1 所示。

表 1 不同模型误差评估表

Table 1 Error evaluation of different models

预测模型	MAE/kW	RMSE/kW	MAPE/%
BP	42.37	66.91	52.78
LSTM	34.35	50.64	43.12
WT-LSTM	20.16	38.32	42.55
EMD-LSTM	23.34	31.66	42.11
VMD-BP	17.98	13.94	50.66
VMD-LSTM	5.03	5.89	19.63
RR-BP	42.30	66.89	50.70
RR-LSTM	33.27	51.44	41.87
RR-WT-LSTM	19.42	35.48	41.55
RR-EMD-LSTM	18.39	25.83	38.85
RR-VMD-BP	15.75	11.07	39.39
RR-VMD-LSTM	4.64	4.89	17.96

对比表 1 中使用 RR 预处理数据前后的预测性能可知, 将采集的原始数据作为输入的效果并不理

想, 预测的功率存在负值并且误差较大, 而利用 RR 处理后的数据不存在负值。以 MAE 为例, 若考虑 RR、LSTM、WT-LSTM、EMD-LSTM 和 VMD-LSTM 的误差分别改善了 3.14%、3.67%、21.21% 和 7.75%。RR 能够改善误差, 主要是因为 LSTM 网络输入数据的类型与学习的有效性有关, 而采集的风电功率存在负值和零值等异常点, 大量的异常点势必会降低 LSTM 的学习效果。

从表 1 的前 4 种模型中可以看出, 单独使用 LSTM 的预测效果最差, 使用分解后风电功率数据进行预测的误差较小, 这说明对风电功率数据先分解再预测的方法提升了 LSTM 的学习效果。与 LSTM 相比, WT-LSTM、EMD-LSTM 和 VMD-LSTM 的预测误差 MAE 分别降低了 41.31%、32.05% 和 85.36%; RMSE 分别降低了 24.33%、37.48% 和 88.37%; MAPE 分别降低了 2.90%、2.34% 和 54.48%。VMD 的提升效果最为明显, 这是因为 VMD 具有自适应和完全非递归的特点, 故鲁棒性更强、分解效果更好。

对比表 1 中 BP、VMD-BP、RR-BP、RR-VMD-BP 和 LSTM、VMD-LSTM、RR-LSTM、RR-VMD-LSTM, 发现使用 LSTM 的整体性能优于使用 BP 的预测模型。相比于 BP, 使用 LSTM 的 MAE、RMSE、MAPE 分别提升了 18.93%、24.32% 和 18.30%。这是因为 LSTM 具有长时记忆功能, 并且改善了梯度消失问题, 此外, 它比 BP 的非线性能力和泛化性更强。

将表 1 中的 RR-VMD-LSTM、VMD-LSTM 和 LSTM 进行比较, 可以清晰地发现 RR-VMD-LSTM 预测模型的效果优于其他两个模型。

综上所述, 单独使用 RR 或 VMD 能够降低误差, 使用 VMD 处理后的改善更显著; 结合 RR 和 VMD 对数据进行预处理后再使用 LSTM 对风电功率进行预测, 预测结果更准确, 更有利于电网安全稳定。

## 4 结论

本文通过分析采集的风电功率数据, 结合风力发电的特点提出了 RR-VMD-LSTM 风电功率预测模型, 得到的结论如下。

1) RR 方法适用于原始数据中存在大量异常点的情况, 能有效改善预测性能。

2) 分解方法能够提高非平稳的风电功率信号的准确性, VMD 的分解效果更好。

3) RR 和 VMD 均可以提高 LSTM 的性能, VMD 的贡献大于 RR, 组合使用 RR、VMD 和 LSTM 能显著降低风电功率预测误差。

本文提出的 RR-VMD-LSTM 模型也可用于解决光伏功率预测等其他问题。在未来的研究中, 可以考虑将适当的气象要素添加到风电功率的预测中, 还可以使用优化模型提升 LSTM 的网络性能。

## 参考文献

- [1] World B. BP statistical review of world energy. [2020]. <https://www.bp.com/content/dam/bp/business-sites/en/global/corporate/pdfs/energy-economics/energy-outlook/bp-energy-outlook-2020.pdf>.
- [2] WANG Y, HU Q, LI L, et al. Approaches to wind power curve modeling: a review and discussion[J]. *Renewable and Sustainable Energy Reviews*, 2019, 116: 1-21.
- [3] 钟浩, 郝亚群, 刘海涛, 等. 考虑风电消纳的风-蓄联合系统 N-1 安全校正方法[J]. *电网与清洁能源*, 2019, 35(2): 78-86.  
ZHONG Hao, HAO Yaqun, LIU Haitao, et al. N-1 security rescheduling method for wind-storage combined system considering wind power consumption[J]. *Power System and Clean Energy*, 2019, 35(2): 78-86.
- [4] 李俊卿, 李秋佳, 石天宇, 等. 基于数据挖掘的风电功率预测特征选择方法[J]. *电测与仪表*, 2019, 56(10): 87-92.  
LI Junqing, LI Qiuji, SHI Tianyu, et al. Feature selection method for wind power prediction based on data mining[J]. *Electrical Measurement & Instrumentation*, 2019, 56(10): 87-92.
- [5] 刘强, 胡志强, 周宇, 等. 基于 CEEMD 和随机森林算法的短期风电功率预测[J]. *智慧电力*, 2019, 47(6): 71-76, 94.  
LIU Qiang, HU Zhiqiang, ZHOU Yu, et al. Short-term wind power forecasting based on CEEMD and random forest algorithm[J]. *Smart Power*, 2019, 47(6): 71-76, 94.
- [6] 郎伟明, 麻向津, 周博文, 等. 基于 LSTM 和非参数核密度估计的风电功率概率区间预测[J]. *智慧电力*, 2020, 48(2): 31-37, 103.  
LANG Weiming, MA Xiangjin, ZHOU Bowen, et al. Wind power probabilistic intervals prediction based on LSTM and nonparametric kernel density estimation[J]. *Smart Power*, 2020, 48(2): 31-37, 103.
- [7] 史加荣, 李雪霞. 基于矩阵补全的气象数据推测[J]. *气象科技*, 2019, 47(3): 420-425.  
SHI Jiarong, LI Xuexia. Meteorological data estimation based on matrix completion[J]. *Meteorological Science and Technology*, 2019, 47(3): 420-425.
- [8] 李富鹏, 沈秋英, 王森, 等. 基于大数据和多因素组合分析的单元制配电网精细化负荷预测[J]. *智慧电力*, 2020, 48(1): 55-62.  
LI Fupeng, SHEN Qiuying, WANG Sen, et al. Refined load forecasting method for unit distribution network based on big data and multiple factors[J]. *Smart Power*, 2020, 48(1): 55-62.
- [9] SUGIYAMA M. Introduction to statistical machine learning[M]. Waltham: Morgan Kaufmann, 2015.
- [10] 毛艳芳, 钟佩军, 孙建军, 等. 基于逆变电源的中低压配电网谐波阻抗测量研究[J]. *电测与仪表*, 2020, 57(8): 70-77.  
MAO Yanfang, ZHONG Peijun, SUN Jianjun, et al. Research on harmonic impedance measurement of medium and low voltage distribution network based on inverter power supply[J]. *Electrical Measurement & Instrumentation*, 2020, 57(8): 70-77.
- [11] HU H, WANG L, TAO R. Wind speed forecasting based on variational mode decomposition and improved echo state network[J]. *Renewable Energy*, 2020, 164: 729-751.
- [12] 张鑫磊, 李根. 基于 IEEMD 与 LS-SVM 组合的短期风电功率多步预测方法[J]. *电测与仪表*, 2020, 57(6): 52-60.  
ZHANG Xinlei, LI Gen. Multi-step prediction method of short-term wind power based on the IEEMD and LS-SVM[J]. *Electrical Measurement & Instrumentation*, 2020, 57(6): 52-60.
- [13] ZHANG D, PENG X, PAN K, et al. A novel wind speed forecasting based on hybrid decomposition and online sequential outlier robust extreme learning machine[J]. *Energy Conversion and Management*, 2019, 180: 338-357.
- [14] 赵倩, 黄景涛. 基于 EMD-SA-SVR 的超短期风电功率预测研究[J]. *电力系统保护与控制*, 2020, 48(4): 89-96.  
ZHAO Qian, HUANG Jingtao. On ultra-short-term wind power prediction based on EMD-SA-SVR[J]. *Power System Protection and Control*, 2020, 48(4): 89-96.
- [15] 任景, 薛晨, 张小东, 等. 含储能及分布式电源的区域电网平衡[J]. *电网与清洁能源*, 2020, 36(12): 75-82.  
REN Jing, XUE Chen, ZHANG Xiaodong, et al. Research on regional power grid balance containing energy storage and distributed generation[J]. *Power System and Clean Energy*, 2020, 36(12): 75-82.
- [16] 王源, 南海鹏, 关欣. 风水储微电网优化调度策略研究[J]. *高压电器*, 2020, 56(5): 216-222.  
WANG Yuan, NAN Haipeng, GUAN Xin. Optimal scheduling strategy of wind-hydro-storage micro-grid[J]. *High Voltage Apparatus*, 2020, 56(5): 216-222.
- [17] CHEN Y, DONG Z, WANG Y, et al. Short-term wind speed predicting framework based on EEMD-GA-LSTM method under large scaled wind history[J]. *Energy Conversion and Management*, 2021, 227: 1-16.

- [18] 胡威, 张新燕, 郭永辉, 等. 基于游程检测法重构 CEEMD 的短时风功率预测[J]. 太阳能学报, 2020, 41(11): 317-325.  
HU Wei, ZHANG Xinyan, GUO Yonghui, et al. Short-term wind power prediction of CEEMD reconstructed based on run-length detection method[J]. Acta Energetica Solaris Sinica, 2020, 41(11): 317-325.
- [19] 田波, 朴在林, 郭丹, 等. 基于改进 EEMD-SE-ARMA 的超短期风功率组合预测模型[J]. 电力系统保护与控制, 2017, 45(4): 72-79.  
TIAN Bo, PIAO Zailin, GUO Dan, et al. Wind power ultra short-term model based on improved EEMD-SE-ARMA[J]. Power System Protection and Control, 2017, 45(4): 72-79.
- [20] DRAGOMIRETSKIY K, ZOZZO D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2013, 62(3): 531-544.
- [21] 余向阳, 赵怡茗, 杨宁宁, 等. 基于 VMD-SE-LSSVM 和迭代误差修正的光伏发电功率预测[J]. 太阳能学报, 2020, 41(2): 310-318.  
YU Xiangyang, ZHAO Yiming, YANG Ningning, et al. Photovoltaic power generation forecasting based on VMD-SE-LSSVM and iterative error correction[J]. Acta Energetica Solaris Sinica, 2020, 41(2): 310-318.
- [22] 韩宏志, 唐振浩. 基于 CEEMDAN 与回声状态网络的风速预测方法[J]. 电力系统保护与控制, 2020, 48(12): 90-96.  
HAN Hongzhi, TANG Zhenhao. Wind speed prediction method based on CEEMDAN and echo state network[J]. Power System Protection and Control, 2020, 48(12): 90-96.
- [23] 韩自奋, 景乾明, 张彦凯, 等. 风电预测方法与新趋势综述[J]. 电力系统保护与控制, 2019, 47(24): 178-187.  
HAN Zifen, JING Qianming, ZHANG Yankai, et al. Review of wind power forecasting methods and new trends[J]. Power System Protection and Control, 2019, 47(24): 178-187.
- [24] MUZAFFAR S, AFSHARI A. Short-term load forecasts using LSTM networks[J]. Energy Procedia, 2019, 158: 2922-2927.
- [25] MEMARZADEH G, KEYNIA F. A new short-term wind speed forecasting method based on fine-tuned LSTM neural network and optimal input sets[J]. Energy Conversion and Management, 2020, 213: 1-15.
- [26] CHEN G, LI L, ZHANG Z, et al. Short-term wind speed forecasting with principle-subordinate predictor based on Conv-LSTM and improved BPNN[J]. IEEE Access, 2020, 8: 67955-67973.
- [27] DE MELO G A, SUGIMOTO D N, TASINAFFO P M, et al. A new approach to river flow forecasting: LSTM and GRU multivariate models[J]. IEEE Latin America Transactions, 2019, 17(12): 1978-1986.
- [28] 刘国昌, 蔡加铭, 闫海洋, 等. 利用稀疏约束非平稳多项式回归去除地震噪声及拾取初至[J]. 石油地球物理勘探, 2020, 55(3): 548-556.  
LIU Guochang, CAI Jiaming, YAN Haiyang, et al. Using sparse-constrained nonstationary polynomial regression to remove seismic noises and picking up first arrival[J]. Oil Geophysical Prospecting, 2020, 55(3): 548-556.
- [29] ARENAS-LÓPEZ J P, BADAoui M. A Fokker-Planck equation based approach for modelling wind speed and its power output[J]. Energy Conversion and Management, 2020, 222.
- [30] 李俊卿, 李秋佳. 基于 Kriging 和长短期记忆网络的风电功率预测方法[J]. 太阳能学报, 2020, 41(11): 241-247.  
LI Junqing, LI Qiujia. Wind power prediction method based on Kriging and LSTM network[J]. Acta Energetica Solaris Sinica, 2020, 41(11): 241-247.
- [31] 周秀, 朱洪波, 马云龙, 等. 基于深度学习的变压器局部放电模式识别研究[J]. 高压电器, 2019, 55(12): 98-105.  
ZHOU Xiu, ZHU Hongbo, MA Yunlong, et al. Partial discharge pattern recognition of transformer based on deep learning[J]. High Voltage Apparatus, 2019, 55(12): 98-105.
- [32] MADHIARASAN M. Accurate prediction of different forecast horizons wind speed using a recursive radial basis function neural network[J]. Protection and Control of Modern Power Systems, 2020, 5(3): 230-238. DOI: 10.1186/s41601-020-00166-8.
- [33] 魏乐, 李思莹. 基于 MEEMD-LSSVM 的风电功率超短期预测研究[J]. 智慧电力, 2020, 48(5): 21-26.  
WEI Le, LI Siying. Ultra-short-term forecast for wind power based on MEEMD-LSSVM[J]. Smart Power, 2020, 48(5): 21-26.

收稿日期: 2021-01-29; 修回日期: 2021-04-26

作者简介:

史加荣(1979—), 男, 通信作者, 博士, 教授, 研究方向为机器学习; E-mail: shijiarong@xauat.edu.cn

赵丹梦(1996—), 女, 硕士研究生, 研究方向为风电场风速与风电功率预测。E-mail: 957458767@qq.com

(编辑 周金梅)