

DOI:10.3969/j.issn.1003-5060.2024.05.020

基于 VMD-ORELM-EC 的超短期风速组合预测模型

谢东良, 邴伦海, 周康, 胡峰

(合肥工业大学 土木与水利工程学院, 安徽 合肥 230009)

摘要:为提高超短期风速预测的精度,文章提出一种基于变分模态分解(variational mode decomposition, VMD)、离群鲁棒极限学习机(outlier-robust extreme learning machine, ORELM)和误差修正(error correction, EC)的超短期风速组合预测模型 VMD-ORELM-EC。首先利用 VMD 将原始风速序列分解,并对每个分解子序列分别建立 ORELM 模型,将各子模型预测结果相加得到模型初步预测序列;然后将原始风速序列与初步预测序列相减得到模型的误差序列,并对误差序列进行 VMD 分解,对分解得到的误差子序列建立 ORELM 模型,从而得到误差预测序列;最后将模型的初步预测序列与误差预测序列组合得到最终的风速预测序列。利用该文提出的预测模型对北京测风塔实测的风速数据进行分析,结果表明模型可以有效挖掘风速序列特性,在超短期风速预测上具有较高的预测性能。

关键词:超短期风速预测;变分模态分解(VMD);离群鲁棒极限学习机(ORELM);误差修正(EC)

中图分类号: TM614 **文献标志码:** A **文章编号:** 1003-5060(2024)05-0703-09

VMD-ORELM-EC based ultra-short-term wind speed prediction model

XIE Dongliang, ZHI Lunhai, ZHOU Kang, HU Feng

(School of Civil and Hydraulic Engineering, Hefei University of Technology, Hefei 230009, China)

Abstract: In this paper, based on the variational mode decomposition (VMD), outlier-robust extreme learning machine (ORELM) and error correction (EC), a combined wind speed prediction model (VMD-ORELM-EC) is proposed to improve the accuracy of ultra-short-term wind speed prediction. Firstly, the original wind speed series are decomposed by the VMD, and the obtained decomposition sub-series are used to build the ORELM sub-models. The prediction results of each sub-model are calculated to obtain the preliminary prediction series. Then, by subtracting the preliminary prediction series from the original wind speed series, the error series of the model can be determined. Accordingly, by employing the VMD and the ORELM, the error prediction series can be obtained. Finally, the preliminary prediction series are combined with the error prediction series to determine the final wind speed prediction series. The proposed VMD-ORELM-EC model is further employed to analyze the field-measured wind speed data obtained from the Beijing anemometer tower. The results show that the model can effectively exploit the characteristics of wind speed series and has high prediction performance in ultra-short-term wind speed prediction.

Key words: ultra-short-term wind speed prediction; variational mode decomposition (VMD); outlier-robust extreme learning machine (ORELM); error correction (EC)

随着社会经济的不断发展,能源需求随之不断增长。对传统能源的严重依赖导致化石能源危

机与环境污染问题日益加剧。近年来,对可再生能源的利用,特别是对风能的开发利用,已受到各

收稿日期: 2022-12-08; **修回日期:** 2023-03-23

基金项目: 国家自然科学基金资助项目(51978230; 52278495); 安徽省自然科学基金杰出青年基金资助项目(2108085J29)

作者简介: 谢东良(1997—),男,重庆市人,合肥工业大学硕士生;

邴伦海(1979—),男,山东菏泽人,博士,合肥工业大学教授,博士生导师。

个国家的高度重视^[1-3]。风能作为清洁能源,具有储量大、分布广等优点,但其同时具有能量密度低、间歇性和不可控等缺点。如果能够实现对风电场风速进行准确的超短期预测,那么电力部门便可以根据风电变化规律及时调整调度计划,从而保证风电机组稳定运行,降低电力系统运行成本。因此对风速进行精确的超短期预测具有重要意义。

目前,风速预测方法总体可分为物理模型和统计模型两类^[4]。物理模型通常基于实时气象条件进行模拟预测,但由于此类模型建模过程复杂且模型输出需要较高的时间成本^[5],因此不适用于超短期风速预测。统计模型通过学习历史风速数据的规律构建数据间的线性或非线形映射关系,具有更快的计算速度和更高的预测精度,更适合超短期风速的预测。基于统计的预测方法主要有自回归移动平均法、反向传播(back propagation, BP)神经网络法、支持向量机法、极限学习机法^[6]以及随机森林法^[7]等。基于这些方法的单一的预测模型原理简单、适应范围广,但也存在着收敛速度慢、网络结构和模型参数难以确定、模型泛化能力不足等缺点。因此采用单一预测模型往往不能获得理想的预测效果^[8]。为提高预测精度,基于统计方法的组合预测模型得到广泛关注和应用,目前组合预测模型主要运用参数优化、信号分解、误差修正 3 种方法。在这 3 种方法中,参数优化方法的合理运用可以有效避免人为因素对模型参数选择的干扰,从而提升模型的精度和泛化能力。文献[9]利用帝国竞争算法实现参数寻优,优化支持向量机回归的关键参数,建立精准的回归预测模型用来预测风速。通过实例证明,优化后的算法与传统人工神经网络相比较,在预测精度上有一定的提升。参数优化方法是通过模型内部的调整来提高模型预测的精度,与此相对,信号分解方法是通过转化模型外部的数据源来降低信号非平稳性和随机性,从而提高模型的预测精度。在这些信号分解技术中,小波变换(wavelet transform, WT)、经验模式分解(empirical mode decomposition, EMD)^[10]和变分模态分解(variational mode decomposition, VMD)已被广泛应用于风速预测。文献[11]提出一种新的改进经验小波变换(improved empirical wavelet transform, IEWT)方法,在此基础上,结合最小二乘支持向量机(least squares support vector machine, LSSVM)提出一种基于改进经验小波变换和最小二

乘支持向量机(IEWT-LSSVM)的风速预测模型,结果表明该模型能有效追踪风速信号的变化,在单步及多步预测上均具有较高的精度。信号分解方法在建模前对信号进行预处理,参数优化方法是在建模过程中对模型进行调整,而误差修正方法则是在建立初步预测模型后对模型的误差进行处理以达到提升模型精度的目的。近年来,组合预测模型中的误差修正方法也逐渐受到相关学者的重视。文献[12]建立一种基于 MSSA-ELM、CSA-LSTM 和 ICEEMDAN 的超短期风速预测模型,该模型使用 CSA-LSTM 对初始预测结果进行校正,实验结果表明,利用 CSA-LSTM 提取误差序列规律信息,有效增强了模型预测能力;文献[13]利用自回归移动平均(integrated moving average, ARIMA)进行短期风速线性成分的预测,利用回声状态网络(echo state network, ESN)进行具有非线性特征的短期风速误差序列的预测,2 种方法预测值累加得到最终的预测值,单步与多步预测的仿真实验表明该混合预测模型具有更小的预测误差;文献[14]提出一种多目标误差回归校正模型,该模型使用延迟算子提高自回归模型的非线性拟合能力,并使用 MOCSMFHO 算法获得模型最优系数。在实际应用中,该误差校正模型可以有效地提升模型的一步、两步和三步的预测性能。

上述研究表明,合理的误差修正策略可以提高组合预测模型的性能。然而,现有的基于误差修正的研究大多数都是直接对具有较强波动性和随机性的误差序列进行建模^[15-17],不能准确描述误差序列的波动。针对误差序列复杂程度高、难以预测的问题,本文提出将信号分解及参数优化引入误差修正模型的理念,即先使用分解技术分解误差序列降低原始误差序列的复杂度,以降低模型的预测难度,然后使用参数优化方法改善模型的泛化性能。由此结合变分模态分解(variational mode decomposition, VMD)、离群鲁棒极限学习机(outlier-robust extreme learning machine, ORELM)和误差修正(error correction, EC),本文提出一种超短期风速组合预测模型 VMD-ORELM-EC,并使用北京某测风塔的实测风速数据验证模型的有效性。

1 基于 VMD-ORELM-EC 的组合预测模型

本文提出的基于 VMD-ORELM-EC 的组合预测模型由分解部分、初步建模部分和误差修正

3 个部分组成。在该模型中,分解部分使用 VMD 分解风速以降低速序列的非平稳性和复杂性;初步建模部分负责对分解得到的子序列进行建模,在建模时采用多目标蜻蜓算法 (multi-objective dragonfly algorithm, MODA) 来增强模型的泛化性能;误差修正部分使用 VMD 算法降低误差序列的预测难度。最后将初步建模部分预测的风速与误差修正部分的预测序列相叠加,即可得到最终预测风速。

1.1 模型步骤

本文所提模型流程如图 1 所示。

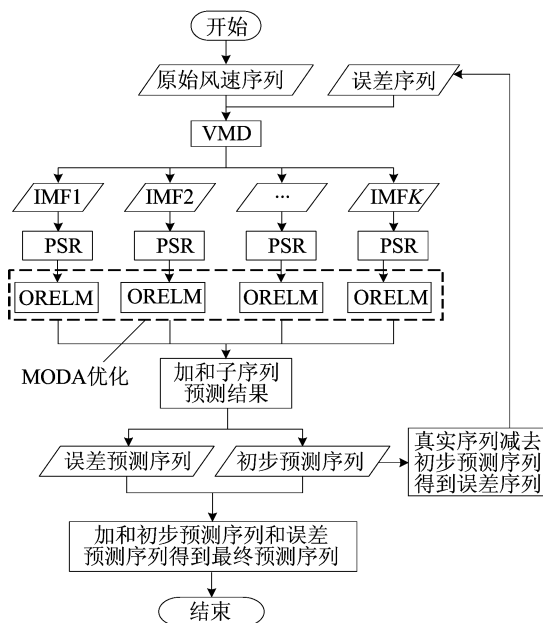


图 1 基于 VMD-ORELM-EC 的组合预测模型流程

模型步骤如下:

1) 输入原始风速序列,使用 VMD 将原始风速设为 K 个子序列,以降低原始数据的非平稳性和随机性。

2) 归一化各分量序列,使用相空间重构技术 (phase space reconstruction, PSR) 重构各序列,以确定各分量模型的输入输出。

3) 建立各子序列的 ORELM 模型,使用 MODA 优化各模型的超参数,增强模型的泛化性能。使用训练好的各模型进行预测并将各模型的预测结果相加,得到风速的初步预测序列。

4) 将原始风速序列减去初步预测序列得到模型的误差序列。

5) 使用 VMD 分解误差序列得到误差子序列,利用 MODA 优化的 ORELM 对误差子序列进行建模,叠加误差子序列模型的预测结果,得到误差预测序列。

6) 将模型初步预测序列和误差预测序列相加得到最终风速预测结果。

1.2 相关算法原理

本文提出的 VMD-ORELM-EC 组合预测模型建模步骤中涉及到 VMD、PSR、MODA 和 ORELM 4 种算法,本节主要对这些基本算法的原理进行详细介绍。

1.2.1 变分模态分解(VMD)

变分模态分解^[18]是一种自适应、准正交和完全非递归的分解算法,其使用希尔伯特变换和维纳滤波器将信号分解为几个有限带宽的固有模式函数。与经验模态分解相比,该算法具有较小的端点效应。同时该算法具有较好的噪声鲁棒性,在风速预测领域应用广泛。该算法的核心过程为变分问题的构造与求解,需要构造的变分问题为:

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

其中: u_k 为第 k 个模态分量; ω_k 为对应分量的中心频率; f 为原始信号; $\delta(t)$ 为狄拉克函数。

通过引入惩罚因子 α 和拉格朗日乘子 λ ,可将式(1)的变分约束问题转化为无约束的变分问题,具体可表述为:

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

式(2)无约束变分问题可通过交替方向乘子法求解。迭代更新 u_k, ω_k, λ 的公式为:

$$\begin{aligned} \hat{u}_k^{n+1}(\omega) = & \left[\hat{f}(\omega) - \sum_{i < k} \hat{u}_i^{n+1}(\omega) - \sum_{i > k} \hat{u}_i^{n+1}(\omega) + \frac{\hat{\lambda}^n(\omega)}{2} \right] / \\ & [1 + 2\alpha(\omega - \omega_k^n)^2] \end{aligned} \quad (3)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k^{n+1}(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k^{n+1}(\omega)|^2 d\omega} \quad (4)$$

$$\hat{\lambda}^{n+1}(\omega) = \hat{\lambda}^n(\omega) + \tau [\hat{f}(\omega) - \sum_{k=1}^K |\hat{u}_k^{n+1}(\omega)|] \quad (5)$$

当迭代满足式(6)的收敛条件时,则停止更新并输出各模态子序列。

$$\sum_{k=1}^K \frac{\|\hat{u}_k^{n+1} - \hat{u}_k^n\|_2}{\|\hat{u}_k^n\|_2} < e \quad (6)$$

其中, e 为收敛误差。

1.2.2 相空间重构(PSR)

Takens 定理认为混沌系统中任一分量的演化均由与之相互作用的其他分量所决定^[19], 因此这些分量的信息隐含在任一分量的发展过程中。当重构一个状态空间时, 只需考察其中一个分量, 并将该分量的固定时间延迟点上的值作为新维处理, 由此可以重构出与原动力系统基本等价的相空间。相空间重构具体步骤如下。

对于一组时间序列:

$$\{x(i) \mid i = 1, 2, \dots, n\} \quad (7)$$

如果嵌入维数和时间延迟为 m 和 τ , 那么相空间中的相点个数为:

$$M = n - (m - 1)\tau \quad (8)$$

重构后构造出的相空间向量 $\mathbf{X}_i (i=1, 2, \dots, N)$ 为:

$$\begin{cases} \mathbf{X}_1 = [x(1), x(1+\tau), \dots, x(1+(m-1)\tau)], \\ \mathbf{X}_2 = [x(2), x(2+\tau), \dots, x(2+(m-1)\tau)], \\ \vdots \\ \mathbf{X}_M = [x((M)), x(M+\tau), \dots, x(M+(m-1)\tau)] \end{cases} \quad (9)$$

嵌入维数 m 和延迟时间 τ 的选择对重构相空间非常关键, 本文采用互信息法^[20]求风速时间序列的延迟时间, 采用虚假邻点法^[21]求其嵌入维数。

1.2.3 多目标蜻蜓算法(MODA)

多目标蜻蜓算法^[22]的灵感来源于蜻蜓种群的捕食和迁徙, 其本质是通过引入外族存档和新的优选方案使得蜻蜓优化算法(dragonfly algorithm, DA)能够处理多目标问题。在该算法中, 静态群行为是蜻蜓聚集在小区域内进行捕食, 动态群行为则是蜻蜓沿着共同方向进行远距离迁徙。该算法通过 5 种个体行为(分离行为、结对行为、内聚行为、觅食行为和避敌行为)实现蜻蜓位置的更新。其中, 分离行为是为了避免相邻个体之间的碰撞, 第 i 个蜻蜓分离时位置向量 \mathbf{S}_i 为:

$$\mathbf{S}_i = -\sum_{j=1}^M (\mathbf{X} - \mathbf{X}_j) \quad (10)$$

其中: \mathbf{X} 为个体当前的位置; M' 为相邻蜻蜓的数量; \mathbf{X}_j 为第 j 个相邻蜻蜓所在的位置。

结对行为代表相邻个体之间的速度保持一致, 第 i 个蜻蜓结对时的位置向量 \mathbf{A}_i 可表示为:

$$\mathbf{A}_i = \frac{\sum_{j=1}^M \mathbf{V}_j}{N} \quad (11)$$

其中: \mathbf{V}_j 为相邻第 j 个蜻蜓的速度。

内聚行为表示个体向中心靠拢的趋势, 第 i 个蜻蜓在内聚时的位置向量 \mathbf{C}_i 为:

$$\mathbf{C}_i = \frac{\sum_{j=1}^M \mathbf{X}_j}{M'} - \mathbf{X} \quad (12)$$

觅食行为代表蜻蜓为了生存而寻找食物, 可表示为:

$$\mathbf{F}_i = \mathbf{X}^+ - \mathbf{X} \quad (13)$$

其中: \mathbf{F}_i 为第 i 个蜻蜓觅食时的位置向量; \mathbf{X}^+ 为食物所在的位置。

避敌行为可表示为:

$$\mathbf{E}_i = \mathbf{X}^- + \mathbf{X} \quad (14)$$

其中: \mathbf{E}_i 为第 i 个个体逃避天敌时所处的位置; \mathbf{X}^- 为其天敌所在位置。

为了更新蜻蜓的位置并模拟其飞行行为, 设置了步长向量和位置向量。其中, 第 t 次迭代时步长向量 $\Delta \mathbf{X}_{t+1}$ 为:

$$\Delta \mathbf{X}_{t+1} = (s\mathbf{I} + a\mathbf{A}_i + c\mathbf{C}_i + f\mathbf{F}_i + e\mathbf{E}_i) + \omega \Delta \mathbf{X}_t \quad (15)$$

其中: s, a, c, f, e 分别为 5 种行为的权重; ω 为惯性权重。

第 $t+1$ 次迭代蜻蜓的位置向量 \mathbf{X}_{t+1} 可表示为:

$$\mathbf{X}_{t+1} = \mathbf{X}_t + \Delta \mathbf{X}_{t+1} \quad (16)$$

1.2.4 离群鲁棒极限学习机(ORELM)

离群鲁棒极限学习机^[23]是根据鲁棒分析理论以及压缩感知理论建立的一种机器学习模型。相比于极限学习机(extreme learning machine, ELM), ORELM 在训练过程中采用基于 1-范数而不是基于 2-范数的误差损失来降低数据集中离群值的干扰, 提高模型的预测能力。

在 ORELM 模型中, 训练集中第 j 个输入 \mathbf{I}_j 和对应的输出 y_j 的数学关系可表示为:

$$\sum_{i=1}^L \beta_i g(\omega_i \mathbf{I}_j + b_i) = y_j, \quad j = 1, 2, \dots, N \quad (17)$$

其中: β_i 为第 i 个隐层节点的输出权值; $g(\cdot)$ 为激活函数; L 为隐层节点数; ω_i 为连接第 i 个隐层节点与输入层的权值向量; b_i 为隐含层第 i 个节点的随机偏置; N 为训练样本数。

因此, N 个训练样本通过上述函数关系可组成线性系统, 即

$$\mathbf{H} \boldsymbol{\beta} = \mathbf{y} \quad (18)$$

其中, \mathbf{H} 为隐含层输出矩阵, 即

$$H = \begin{bmatrix} g(\omega_1 I_1 + b_1) & \cdots & g(\omega_L I_1 + b_L) \\ \vdots & & \vdots \\ g(\omega_1 I_N + b_1) & \cdots & g(\omega_L I_N + b_L) \end{bmatrix}_{N \times L};$$

$$\beta = [\beta_1 \ \beta_2 \ \cdots \ \beta_L]^T; y = [y_1 \ y_2 \ \cdots \ y_N]^T.$$

在求解输出权值时,使用基于 1-范数的误差损失来提高预测模型的鲁棒性,即

$$\min_{\beta} \left(\|e\|_1 + \frac{1}{c} \|\beta\|_2 \right) \quad (19)$$

其中: e 为训练误差; c 为调节系数。

随后使用增广拉格朗日乘子法求解上述问题的最优解。对应的增广拉格朗日函数式为:

$$L_{\mu}(e, \beta, \lambda) = \|e\|_1 + \frac{1}{c} \|\beta\|_2 + \lambda^T (y - H\beta - e) + \frac{\mu}{2} \|y - H\beta - e\|_2^2 \quad (20)$$

其中: λ 为拉格朗日乘数矩阵; μ 为大于 0 的惩罚因子,取 $\mu = 2N / \|y\|_1$ 。

因此,可通过迭代更新式(21)求解上述优化问题,即

$$\begin{cases} \beta_{k+1} = \operatorname{argmin}_{\beta} L_{\mu}(e_k, \beta_k, \lambda_k), \\ e_{k+1} = \operatorname{argmin}_{e} L_{\mu}(e_k, \beta_k, \lambda_k), \\ \lambda_{k+1} = \lambda_k + \mu(y - H\beta_{k+1} - e_{k+1}) \end{cases} \quad (21)$$

其中, k 为迭代次数。

将求解所得的权值 β 带入 $\hat{y} = H\beta$ 中,即可得到预测结果。

2 算例分析

2.1 风速实测数据

本文使用的数据来自北京某测风塔,数据观测时间范围为 2003-05-01—2003-05-25。在该时间段内分别取 120、280 m 2 个高度处的 10 min 平均风速序列作为本次实验的 2 个数据集。在每个数据集中,前 3 240 个采样点(前 90%)作为训练集,后 360 个采样点(后 10%)作为测试集。2 个高度处风速数据的统计指标(最大值、最小值、平均值和标准差)见表 1 所列。原始风速序列如图 2 所示。

表 1 各高度风速数据集统计指标 单位:m/s

高度/m	最大风速	最小风速	平均风速	风速标准差
120	10.035	0.049	2.653	1.440
280	13.941	0.060	3.585	2.297




图 2 原始风速序列

2.2 模型评价指标

为定量评价不同模型的预测精度,本文采用 4 种常用的评价指标对模型进行对比,即平均绝对误差(mean absolute error, MAE) E_{MA} 、平均绝对百分比误差(mean absolute percentage error, MAPE) E_{MAP} 、误差序列标准差(standard deviation of error sequence, SDE) S_{DE} 和可决系数 R^2 。其中: E_{MA} 、 E_{MAP} 从误差大小角度评价预测精度,值越小说明预测效果越好; R^2 表示模型在多大程度上解释了因变量的变化,或者衡量了模型对观测值的拟合程度,值越大说明预测效果越好; S_{DE} 从预测误差的离散程度评价模型的稳定性,值越小说明预测效果越稳定。4 个指标的计算公式如下:

$$E_{MA} = \frac{1}{N} \sum_{i=1}^N |x(i) - \hat{x}(i)| \quad (22)$$

$$E_{MAP} = \frac{1}{N} \sum_{i=1}^N \left| \frac{x(i) - \hat{x}(i)}{x(i)} \right| \times 100\% \quad (23)$$

$$S_{DE} = \sqrt{\frac{1}{N} \sum_{i=1}^N \left[x(i) - \hat{x}(i) - \frac{1}{N} \sum_{i=1}^N (x(i) - \hat{x}(i)) \right]^2} \quad (24)$$

$$R^2 = \frac{\sum_{i=1}^N [\hat{x}(i) - \bar{x}]^2}{\sum_{i=1}^N [x(i) - \bar{x}]^2} \quad (25)$$

其中: $x(i)$ 为 i 时刻风速实际值; $\hat{x}(i)$ 为 i 时刻风速预测值; \bar{x} 为实际风速的平均值。

2.3 数据分解与实验设计

首先对风速序列进行 VMD 分解,本文 VMD 算法的惩罚因子 α 取 2 000、保真系数 τ 取 0.3 以保证数据分解的保真度。以 120 m 高度处风速序列为例,经过试验确定该序列的最优分解阶数 $K=5$ 。基于此,可以得到 120 m 高度处风速序列

训练集部分分解结果,如图 3 所示。




图 3 120 m 高度处风速序列训练集部分分解结果

为验证本文提出模型的有效性,本文分别建立以下 3 类模型进行讨论。

1) 单学习器类。直接以 MODA 优化的各基学习器分别建立预测模型,基学习器具体包括 ORELM、KNN 和 GRNN 模型。

2) 风速分解类。与单学习器类相比,区别在于该类模型添加了基于 VMD 的分解模块对原始风速序列进行预处理。具体模型包括 VMD-ORELM、VMD-KNN、VMD-GRNN 模型。

3) 风速分解-误差修正类。在风速分解类模型的基础上添加了基于分解的误差修正模块。具体包括 VMD-KNN-EC、VMD-GRNN-EC、VMD-ORELM-EC 模型。

2.4 结果分析

3 类模型都是在前一类模型上递进添加了相关模块。而在每类模型内部,各模型之间的区别在于基学习器选择的不同。本文提出的 VMD-ORELM-EC 模型即属于风速分解-误差修正类模

型,并且使用 ORELM 作为基学习器。为了说明 VMD-ORELM-EC 模型所基于的中间模块(风速分解模块、误差修正模块)的有效性,同时验证该模型的优越性,以下分 2 个部分进行模型性能讨论。

2.4.1 风速分解类和单学习器类模型的性能对比

为了验证分解模块的有效性,本节将对 3 个风速分解类模型的预测结果进行分析,并将其结果与各自对应的单预测模型结果进行对比,试验结果见表 2、表 3 所列。本文涉及到的所有模型的预测结果如图 4 所示,框出范围局部放大后的预测结果如图 4b、图 4d 所示。

表 2 各单学习器模型预测性能对比

高度/m	预测模型	评价指标			
		$E_{MA}/(m/s)$	$E_{MAP}/\%$	$S_{DE}/(m/s)$	R^2
120	ORELM	0.531	24.177	0.752	0.757
	KNN	0.565	26.556	0.791	0.728
	GRNN	0.562	27.289	0.800	0.723
280	ORELM	0.671	34.798	0.917	0.818
	KNN	0.685	37.165	0.928	0.812
	GRNN	0.707	39.940	0.948	0.805

表 3 各分解模型预测性能对比

高度/m	预测模型	评价指标			
		$E_{MA}/(m/s)$	$E_{MAP}/\%$	$S_{DE}/(m/s)$	R^2
120	VMD-ORELM	0.301	12.517	0.393	0.934
	VMD-KNN	0.394	18.186	0.511	0.888
	VMD-GRNN	0.384	17.246	0.510	0.888
280	VMD-ORELM	0.322	15.651	0.438	0.958
	VMD-KNN	0.431	22.865	0.596	0.923
	VMD-GRNN	0.425	24.102	0.587	0.926

从表 2、表 3 可以看出,在采用相同基学习器的条件下,风速分解类模型提供了比单学习器类模型本身更高的预测精度。为定量比较不同模型的预测精度,使用相对改善作为评价模型精度提升的指标。相对改善为改善后该指标值与改善前指标值的差与改善前指标之比,对于其他 3 个指标来说则是该百分比的相反数。在 120 m 高度处的风速预测指标对比中,VMD-ORELM 模型与 ORELM 模型相比, E_{MA} 、 E_{MAP} 、 S_{DE} 、 R^2 4 种指标的相对改善分别为 43.38%、48.23%、47.74%、23.37%;VMD-GRNN 模型相比于 GRNN 模型,上述 4 种指标的相对改善分别为 31.57%、36.80%、36.31%、22.79%。从表 2、表 3 还可以看出,在 2 个数据集中 VMD-KNN 模型与单 KNN 模型相比, E_{MA} 分别相对改善了

30.30%、37.10%; E_{MAP} 分别相对改善了31.52%、38.48%; S_{DE} 分别相对改善了35.41%、35.76%; R^2 分别相对改善了21.94%、13.67%。

总之,在不同高度数据集的结果对比中,信号分解模块显著地提高了风速预测的精度,相似的结论也可从图4中得到。图4a、图4c中单学习器类模型和风速分解类模型的预测结果曲线均能很好地反映实际风速的变化趋势。

从图4a、图4c可以看出,3种单学习器类模型均能稳定预测出各高度处测试集风速的变化趋势。但是使用性能指标定量对3种单一模型进行比较时,可以发现相比于KNN模型和GRNN模型,ORELM模型在2个数据集的4个指标上都具有最好的表现。证明了相对于其他单一模型,基于ORELM的单一模型能更精确捕捉到风速

的变化规律。

但是,局部放大曲线(图4b、图4d)表明,单学习器类模型的预测曲线产生了明显的滞后现象,而对应的风速分解类模型则明显降低了滞后的程度,因此表现出有更高的拟合程度和更小的偏差。分析原因为VMD算法可将具有强非线性、非平稳性及随机性特征的风速序列转换为一系列相对平稳且复杂程度更低的分量,增加了风速序列的可预测性。

从表3可以看出,与VMD-KNN和VMD-GRNN模型相比,VMD-ORELM模型在2个数据集的4个预测指标上均取得了最佳预测效果,再次证明了ORELM模型相对于其他模型来说具有更好的学习能力,更适合用作超短期风速预测的基学习器。

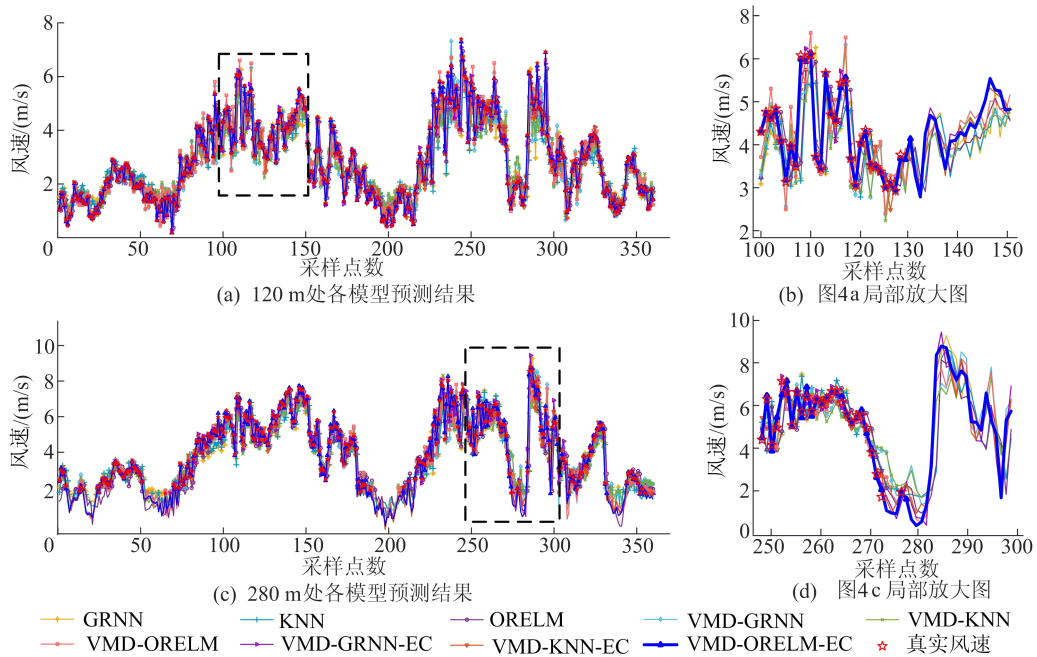


图4 各模型预测结果对比

2.4.2 风速分解-误差修正类模型的性能

为了验证本文所提出的VMD-ORELM-EC模型的优越性,下面将说明该模型基于误差修正模块的有效性,并研究不同基学习器对实验结果的影响。同一高度、同一基学习器下不同种类模型的误差绝对值序列如图5、图6所示,风速分解-误差修正类模型误差指标见表4所列。

从图4b、图4d可以看出,风速分解-误差修正类的3种模型与风速分解类的3种模型相比能够更精确地贴合实际风速序列曲线,与对应的3种基学习器类模型相比能够显著地降低预测的滞后程度。从图5、图6可以看出,在同样的数据

集、使用相同的基学习器的条件下,风速分解类模型和风速分解-误差修正类模型均能有效降低误差绝对值序列的振荡区间和振荡幅值。此外,风速分解-误差修正类模型在3类模型中具有最低的误差绝对值序列振荡区间和幅值。

进一步比较表3和表4,可以发现在2个高度的数据集中,风速分解-误差修正类模型的误差评价指标均优于风速分解类模型的指标。以基学习器为ORELM的模型为例,通过横向比较VMD-ORELM与VMD-ORELM-EC模型,可以看出在2个数据集中 E_{MA} 分别下降0.271、0.209 m/s, S_{DE} 分别下降0.354、0.286 m/s, R^2

分别提高 0.065、0.037。同样,当采用其他基学习器对比时,也可以看出风速分解-误差修正类模型相对于风速分解类模型的性能明显提升。这表明基于误差分解的误差修正模块可以有效地提取误差序列中的剩余信息,从而精确地实现对误差序列的预测,提高模型整体预测精度。

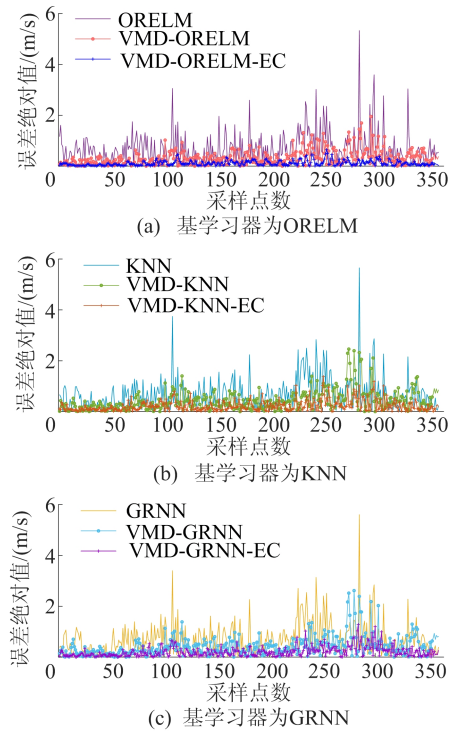


图 5 120 m 高度处各模型误差绝对值

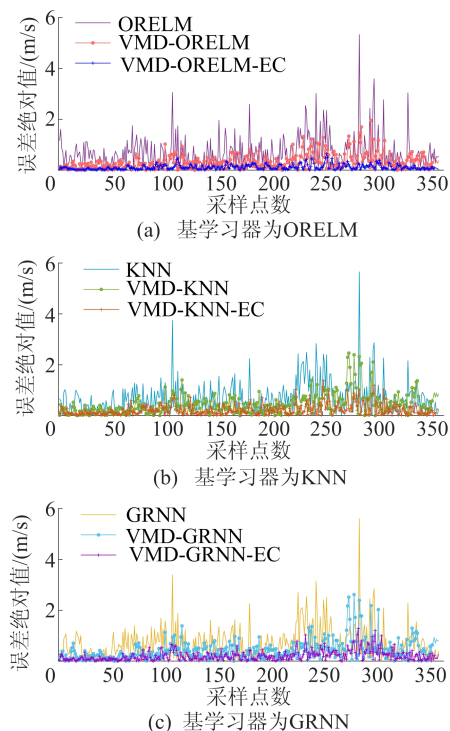


图 6 280 m 高度处各模型误差绝对值

表 4 风速分解-误差修正模型预测性能对比

高度/ m	预测 模型	$E_{MA}/$ (m/s)	$E_{MAP}/$ %	$S_{DE}/$ (m/s)	R^2
120	VMD-ORELM-EC	0.030	1.324	0.039	0.999
	VMD-KNN-EC	0.203	9.320	0.281	0.966
	VMD-GRNN-EC	0.112	4.757	0.152	0.990
280	VMD-ORELM-EC	0.113	5.477	0.152	0.995
	VMD-KNN-EC	0.228	12.330	0.318	0.978
	VMD-GRNN-EC	0.210	9.336	0.294	0.981

从表 4 可以看出,相较于 VMD-KNN-EC 模型和 VMD-GRNN-EC 模型,本文所提出的 VMD-ORELM-EC 模型在各数据集所有指标下均具有最佳的预测效果。同时,结合表 2、表 3 可以看出,本文提出模型在所有供比较的 9 种模型中具有最佳的预测性能,从而证明本文所提出的模型在超短期风速序列预测应用中的优越性。

3 结 论

本文提出了一种基于 ORELM、VMD、EC 的超短期风速预测模型 VMD-ORELM-EC,利用北京某测风塔的实测数据集对模型的预测性能进行对比分析,得出以下结论。

- 1) 风速分解类模型的预测精度优于对应的单学习器类模型,表明基于 VMD 的分解策略是提高风速预测性能的有效手段。
- 2) 风速分解-误差修正类模型的预测精度均优于对应的风速分解类模型,表明基于误差分解的误差修正模型可以有效地挖掘分解类模型误差序列中的剩余信息,从而提升模型整体预测精度和稳定性。

3) 在本文涉及到的 3 类预测模型中,以 ORELM 为基学习器的模型具有最好的预测指标,表明 ORELM 为基学习器具有最佳的学习能力。同时,在所有涉及的 9 种模型中,本文提出的 VMD-ORELM-EC 模型具有最佳的预测性能。

本文提出的 VMD-ORELM-EC 超短期风速预测模型,不仅可以应用在风速预测中,对于其他具有波动性的预测问题也同样适用,如流量预测、负荷预测等。

[参 考 文 献]

[1] 孙斌,姚海涛. 基于 PSO 优化 LSSVM 的短期风速预测[J]. 电力系统保护与控制, 2012, 40(5): 85-89.
 [2] 中商产业研究院. 五幅图看懂全球风力发电行业现状及主要国家市场占比(图表)[EB/OL]. (2018-11-16)[2022-10-

- 22]. [https://www. askci. com/news/chanye/20181116/1712481136902. shtml](https://www.askci.com/news/chanye/20181116/1712481136902.shtml).
- [3] 北极星电力网. GWEC 发布 2022 全球海上风电报告[EB/OL]. (2022-07-01)[2022-10-22]. <https://news. bjx. com. cn/html/20220701/1237788. shtml>.
- [4] 王宽. 基于 IPSO-BP 神经网络的短期风电功率预测研究[D]. 银川:宁夏大学,2022.
- [5] 张泰豪,殷锋,袁平. 风速及风功率预测方法综述[J]. 现代计算机,2021(8):45-48.
- [6] HUA L,ZHANG C,PENG T, et al. Integrated framework of extreme learning machine (ELM) based on improved atom search optimization for short-term wind speed prediction[J]. *Energy Conversion and Management*,2022,252:115102.
- [7] 朱昶胜,李岁寒. 基于改进果蝇优化算法的随机森林回归模型及其在风速预测中的应用[J]. 兰州理工大学学报,2021,47(4):83-90.
- [8] 芦婧,曾明. 短期风速的 Adaboost-GRNN 组合预测模型[J]. 电力系统及其自动化学报,2019,31(4):70-76.
- [9] 尤亚锋,周武能. 基于 ICA 优化 SVR 的风电场短期风速预测[J]. 计算机与数字工程,2020,48(7):1547-1551.
- [10] WANG J,ZHANG W,LI Y, et al. Forecasting wind speed using empirical mode decomposition and Elman neural network[J]. *Applied Soft Computing*,2014,23:452-459.
- [11] 向玲,邓泽奇. 基于改进经验小波变换和最小二乘支持向量机的短期风速预测[J]. 太阳能学报,2021,42(2):97-103.
- [12] 李嘉文,盛德仁,李蔚,等. 基于多目标优化和误差修正的短期风速预测[J]. 太阳能学报,2022,43(8):273-280.
- [13] 田中大,李树江,王艳红,等. 基于 ARIMA 与 ESN 的短期风速混合预测模型[J]. 太阳能学报,2016,37(6):1603-1610.
- [14] CHEN J,LIU H,CHEN C, et al. Wind speed forecasting using multi-scale feature adaptive extraction ensemble model with error regression correction[J]. *Expert Systems with Applications*,2022,207:117358.
- [15] 黄元生,杨磊,高冲,等. 基于经验模态分解和误差校正的短期风速预测[J]. 智慧电力,2020,48(1):35-41.
- [16] 韩静怡. 基于改进神经网络的混合风速短期预测模型[D]. 北京:华北电力大学,2021.
- [17] 黄文聪,张宇,张隽怡,等. 基于时间序列突变误差校正的超短期风速联合预测模型[J]. 昆明理工大学学报(自然科学版),2020,45(4):73-84,119.
- [18] DRAGOMIRETSKIY K,ZOSSO D. Variational mode decomposition[J]. *IEEE Transactions on Signal Processing*,2013,62(3):531-544.
- [19] STARK J,BROOMHEAD D S, DAVIES M E, et al. Takens embedding theorems for forced and stochastic systems[J]. *Nonlinear Analysis: Theory, Methods & Applications*,1997,30(8):5303-5314.
- [20] ZHANG S,JIA J,GAO M, et al. Study on the parameters determination for reconstructing phase-space in chaos time series[J]. *Acta Physica Sinica*,2010,59(3):1576-1582.
- [21] 孙晓婷. 基于 LSSVM-ARIMA 的城市短期供水量组合预测模型[D]. 昆明:昆明理工大学,2019.
- [22] MIRJALILI S. Dragonfly algorithm: a new meta-heuristic optimization technique for solving single-objective, discrete, and multi-objective problems[J]. *Neural Computing and Applications*,2016,27(4):1053-1073.
- [23] ZHANG K,LUO M. Outlier-robust extreme learning machine for regression problems[J]. *Neurocomputing*,2015,151:1519-1527.

(责任编辑 张 镝)

(上接第 654 页)

- [9] HUANG Y,ZENG X,WANG W D, et al. High-resolution flexible temperature sensor based on graphite-filled polyethylene oxide and polyvinylidene fluoride composites for body temperature monitoring [J]. *Sensors and Actuators A (Physical)*,2018,278(1):1-10.
- [10] ZHAO Y N,HUANG Y,HU W, et al. Highly sensitive flexible strain sensor based on threadlike spandex substrate coating with conductive nanocomposites for wearable electronic skin [J]. *Smart Materials & Structures*,2019,28(3):035004.
- [11] BAI L,LI Z X,ZHAO S Z, et al. Covalent functionalization of carbon nanotubes with hydroxyl-terminated polydimethylsiloxane to enhance filler dispersion, interfacial adhesion and performance of poly(methylphenylsiloxane) composites [J]. *Composites Science and Technology*,2018,165:274-281.
- [12] CHUN S,SON W,KIM H, et al. Self-powered pressure and vibration-sensitive tactile sensors for learning technique-based neural ginger skin [J]. *Nano Letters*,2019,19:3305-3312.
- [13] BENGTT K. *Statistics for dummies*[M]. 2nd ed. Hoboken: Wiley Publishing,2011:284-285.

(责任编辑 张 镝)