

基于自适应组合模型的超短期风速预测

关永锋^{1,2}, 喻敏^{1,2}, 胡佳^{1,2}

(1. 冶金工业过程系统科学湖北省重点实验室(武汉大学), 湖北 武汉 430081;

2. 武汉科技大学理学院, 湖北 武汉 430065)

摘要: 风电场的风速预测对电力系统的稳定及安全运行有着重大的影响。考虑到风速序列具有间歇性和随机性等特征, 提出一种基于参数优化的变分模态分解及极限学习机的组合模型, 将其用于超短期风速预测。首先, 采用变分模态分解算法将风速序列分解为一系列的平稳分量。以正交性为适应度函数, 利用网格优化算法搜索变分模态分解的关键参数值——分解层数和惩罚因子, 确保分解出来各模态分量之间的信息正交性, 抑制耦合分量的产生。然后, 利用极限学习机对各分量进行预测。针对极限学习机预测不稳定的问题, 采用粒子群算法对其初始权值及阈值进行参数优化, 对于该模型的输入维数则运用自回归差分移动平均模型的定阶结果进行自适应确定。最后, 叠加各分量的预测值作为最终的预测结果。实验结果表明, 所提出的组合模型在预测精度上显著优于其他基准模型。

关键词: 参数优化的变分模态分解; 自回归差分移动平均模型; 粒子群优化算法; 极限学习机; 超短期风速预测

Ultra-short-term wind speed prediction based on an adaptive integrated model

GUAN Yongfeng^{1,2}, YU Min^{1,2}, HU Jia^{1,2}

(1. Hubei Province Key Laboratory of Systems Science in Metallurgical Process, Wuhan University of Science and Technology, Wuhan 430081, China; 2. College of Science, Wuhan University of Science and Technology, Wuhan 430065, China)

Abstract: Wind speed prediction has a significant impact on the stable and safe operation of a power system. According to the intermittent and random nature of wind speed, an integrated model of variational modal decomposition (VMD) based on grid search optimization algorithm (GS) and PSO-ELM is proposed for ultra-short-term wind speed prediction. First, the VMD is used to decompose wind speed sequence into a series of sub-sequences. By taking the orthogonality as the fitness function, the GS is used to search the key parameters of VMD adaptively, including the number of decomposed layers and a penalty factor. The purpose is to ensure information orthogonality between each component and to suppress coupling components. Then, the extreme learning machine (ELM) method is used to predict each sub-sequence. Given the unstable prediction of this model, particle swarm algorithm (PSO) is used to optimize the parameters of the initial weight and threshold, and the input dimension of each sub-sequence is determined adaptively by using the auto-regressive integrated moving average model (ARIMA). Finally, the predicted results of each sub-sequence are superimposed to obtain the final predicted wind speed. The result shows that the proposed integrated model is remarkably superior to all considered benchmark models in prediction accuracy.

This work is supported by the National Natural Science Foundation of China (No. 51877161).

Key words: parameter optimized variational modal decomposition; ARIMA; PSO; ELM; ultra-short-term wind speed prediction

0 引言

随着石油、天然气等传统资源的枯竭和环境污

染等问题日益突出, 风电作为一种技术较为成熟的清洁发电方式, 在电网中的渗透率不断提高^[1-3]。然而, 由于风速的随机性和间歇性, 大规模接入风电会导致电力系统中的电压产生频繁波动而破坏其稳定性^[4-5]。准确地预测风速可以有效地指导风机功率控制, 也是保证大规模风电并网的内在要求和基本任务^[6-8]。因此, 提高风速的预测精度成为提升风电

基金项目: 国家自然科学基金项目资助(51877161); 湖北省教育厅科研计划指导项目资助(2018006); 冶金工业过程系统科学湖北省重点实验室开放基金资助(Y202007)

运行控制水平的一个主要途径。

准确地对风速进行超短期预测,可以减少电力系统备用容量,提高风电穿透功率极限,使电力市场经济效益最大化^[9-10]。目前,常用的超短期风速预测模型包括统计模型^[11-12]、神经网络模型^[13-14]、组合模型^[15-18]以及考虑空间相关性或季风特性的模型^[19-22]。以自回归移动平均模型为代表的统计模型能有效刻画风速序列的走势和周期波动,但这类模型要求数据满足平稳性条件,强行将其用于不平稳数据的预测会导致结果出现伪回归;以反向传播神经网络模型为代表的人工神经网络模型具有较强的非线性映射能力及学习能力,但此类模型参数较多,易产生过拟合现象;组合模型通过引入多尺度分解的方法对原始风速序列进行预处理,然后采用单一预测模型进行预测,此类方法能有效把握风速数据的变化规律,具有较高的预测精度。但由于风速序列自身所具有的非线性、非平稳特性,导致分解出来的分量出现模态混叠现象,影响了模型的预测精度;空间相关模型依据风电场周边站点的风速数据来预测未来风速,对数据样本的依赖性较小,能充分考虑地理位置对风速预测的影响,特别地,在存在季风气候的地区^[22],可进一步利用季风特性对空间相关模型进行改进,但此类模型受测风站位置、风向变化的影响较大。

由于单一模型在超前一步预测中普遍存在滞后问题^[23],本文依据“分解-组合”的思路,从以下两方面入手进行改进。在风速数据预处理方面,采用一种基于非递归分解的变分模态算法(Variational Mode Decomposition, VMD)对风速序列进行自适应分解,该算法能有效缓解经验模态分解(Empirical Mode Decomposition, EMD)等递归分解算法所产生的模态混叠现象,有效降低原始风速的非平稳性和非线性。对分解层数 k 和惩罚因子 α 这两个关键参数则以分量间的正交性为适应度函数,采用网格搜索(Grid search, GS)的寻优方法进行确定。GS算法通过穷举的方式同时对多个参数寻优,不仅使各参数相互解耦,而且能并行计算,可保证在搜索范围内找到全局最优解。利用GS算法优化多尺度分解的方式在故障诊断^[24-26]领域的应用中取得了良好的效果,因此本文将GS-VMD算法应用到风速序列的预处理当中。在预测模型选择方面,采用极限学习机(Extreme Learning Machine, ELM)对分解后获得的各个本征模态函数(Intrinsic Mode Function, IMF)序列进行预测,与常用的人工神经网络模型相比,ELM具有更快的学习速度和泛化能力,针对该模型预测结果不稳定的问题,利用粒子群算法(Particle Swarm Optimization, PSO)对其初始权值及阈值进行优化,以保证该模型预测结果的鲁棒性和

准确性;同时,采用自回归差分移动平均模型(Auto-Regressive Integrated Moving Average model, ARIMA)的定阶结果对ELM模型的输入维数进行确定,与传统的相空间重构法和偏向关系系数法相比,该算法能有效减少模型运行时间且具备自适应能力;最后,将各子序列的预测结果相加获得最终的风速预测值。本文面向风力发电调控系统的应用,目的是缓解风电出力不确定性对电力系统运行调度的不利影响,因此只对风速进行超短期预测。对西班牙某风电场采样间隔为10 min、1 h、2 h的三组风速数据进行超前一步风速预测的实验表明,本文提出的自适应风速超短期预测组合模型具有较好的预测效果。

1 研究方法

1.1 变分模型分解

变分模态分解算法^[27-28]是K.Dragomiretskiy和D.Zosso提出的一种新型时频分析方法。不同于传统的EMD算法,VMD是一种非递归分解方法,其采用迭代的形式求解变分模型的最优解,进而确定每个IMF分量的中心频率及带宽,自适应地分离出若干个具有不同频率成分的模式分量,具有较好的采样效应和噪声鲁棒性,在风速预测领域有广泛的应用。

该算法可分为构造变分问题和求解变分问题两个过程。所构造的变分问题可以表述为

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

式中: u_k 为第 k 个模态分量; ω_k 为中心频率; f 为原始信号。

当引入了惩罚因子 α 和拉格朗日乘子 λ 后,式(1)可转变成无约束的变分问题,具体表达式为

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

采用交替方向乘子法求解该无约束的变分问题,不断更新 u_k 、 ω_k 、 λ ,迭代公式为

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i < k} \hat{u}_i^{n+1}(\omega) - \sum_{i > k} \hat{u}_i^{n+1}(\omega) + \frac{\hat{\lambda}^n(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k^n)^2} \quad (3)$$

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

$$\hat{\lambda}^{n+1}(\omega) = \hat{\lambda}^n(\omega) + \tau \left(\hat{f}(\omega) - \sum_k |u_k^{n+1}(\omega)| \right) \quad (5)$$

当满足式(6)的收敛条件时, 迭代更新停止, 输出各模态子序列。

$$\sum_k \frac{\|\hat{u}_k^{n+1} - \hat{u}_k^n\|_2^2}{\|\hat{u}_k^n\|_2^2} < e \quad (6)$$

式中, e 为收敛误差。

1.2 自回归差分移动平均模型

自回归差分移动平均模型是由 Box 和 Jenkins 提出的一种用于处理非平稳时间序列的模型。ARIMA 模型是将非平稳数据转换成平稳数据后, 对因变量的滞后值及随机误差项的现值和滞后值进行回归所建立的模型, 简记为 ARIMA(p, d, q), 其数学表达式为

$$\left(1 - \sum_{i=1}^p \varphi_i L^i\right) (1-L)^d = \left(1 + \sum_{j=1}^q \theta_j L^j\right) \varepsilon_j \quad (7)$$

式中: p 为自回归项; q 为移动平均项; d 为差分次数; L 为滞后算子; φ_i 为自回归系数; θ_j 为移动平均系数; ε_j 为白噪声过程。

对于 ARIMA 模型的定阶, 可计算其各阶数下相应的 AIC(Akaike Information Criterion)值, 然后寻找 AIC 的极小值, 极小值所对应的阶数即为该模型的最佳阶数, 由此可建立 ARIMA 模型。AIC 准则是衡量 ARIMA 模型拟合优良性的一种标准。

设 $\{X_t, 1 \leq t \leq N\}$ 为一随机时间序列, 采用极大似然估计算法估计其拟合模型 ARIMA(p, d, q) 的参数, 则 AIC 准则函数的定义为

$$\text{AIC}(p, d, q) = -2 \ln L + 2r \quad (8)$$

式中: L 为极大似然估计值; r 为独立参数的个数, $r = p + q$ 。

1.3 极限学习机

极限学习机是一种基于单隐含层前馈神经网络的改进算法, 与传统神经网络模型相比, ELM 结构简单, 不易陷入局部最优, 具有学习速度快、泛化能力好等优点。

设有 M 组不同的随机样本 $(x_i, y_i) \in \mathbf{R}^n$ 。若网络的隐含层神经元个数为 L , 激活函数为 $g(x)$, 隐含层第 i 个节点的输入权值向量为 \mathbf{w}_i , 偏置值

为 b_i , 输出权值向量为 β_i , 于是 SLFN 模型可表示为

$$\sum_{i=1}^L \beta_i g_i(x_j) = \sum_{i=1}^L \beta_i g(\mathbf{w}_i \cdot x_j + b_i) \quad (9)$$

式中, $j = 1, 2, \dots, M$ 。

依据零误差逼近原则, 上述模型能无限逼近 M 组训练样本, 存在 β_i 、 \mathbf{w}_i 和 b_i 使得式(10)成立。

$$\sum_{i=1}^L \beta_i g(\mathbf{w}_i \cdot x_j + b_i) = y_j \quad (10)$$

式中, $j = 1, 2, \dots, M$ 。

对应的矩阵形式为

$$\mathbf{H}\boldsymbol{\beta} = \mathbf{Y}^T \quad (11)$$

式中: \mathbf{H} 为隐含层的输出矩阵; $\boldsymbol{\beta}$ 为权值向量矩阵; \mathbf{Y} 为网络的输出矩阵。

对于 SLFN 模型的训练可以转化为求上式的最小二乘解 $\hat{\boldsymbol{\beta}}$, 即求解下列方程组:

$$\min_{\boldsymbol{\beta}} \|\mathbf{H}\boldsymbol{\beta} - \mathbf{Y}^T\| \quad (12)$$

其解为

$$\hat{\boldsymbol{\beta}} = \mathbf{H}^+ \mathbf{Y}^T \quad (13)$$

式中, \mathbf{H}^+ 为 Moore-Penrose 广义逆矩阵。

2 自适应风速超短期预测模型

2.1 网格搜索优化的变分模态分解

由 VMD 计算过程可以发现, 在运用该算法时需人为确定两个关键参数: 分解层数 k 和惩罚因子 α 。前人在运用该算法时大都只针对分解层数 k 的选取进行讨论, 如采用中心频率法^[9], 对于惩罚因子 α 则采用的是默认值。但是, 惩罚因子 α 对 VMD 分解结果的影响也是不可忽略的, 仅仅考虑分解层数 k 的选取是不够的, 因此, 本文提出将 GS 算法用于 VMD 的参数优化中, 具体步骤如下所述。

1) 确定分解层数 k 和惩罚因子 α 的搜索步长及搜索范围;

2) 根据两个参数的搜索步长和搜索范围在二维平面内进行网格的划分, 每一个网格对应一组参数组合 (k, α) ;

3) 在每一组参数组合下, 对风速数据进行 VMD 分解, 计算各模态分量间的正交性(Index of Orthogonality, IO), 如式(14)。

$$IO = \sum_{i=1}^L \left(\sum_{j=1}^K \frac{u_i(t)u_j(t)}{u^2(t)} \right) \quad (14)$$

式中: L 为信号长度; K 为分量个数; i, j 为分量下标, $i \neq j$ 。

4) 选取正交性最小时所对应的参数组合为最优参数值。

具体地, 运用 GS-VMD 算法对采样间隔为 10 min 的风速数据进行仿真分析。以 1 为递增步长在 [4,10] 范围内和以 100 为递增步长在 [1600, 2300] 范围内分别对分解层数 k 、惩罚因子 α 进行网格搜索, 计算两个参数在不同组合下的 IO 值, 结果如图 1 所示。可发现正交性最小的 IO 值为 0.003 95, 其所对应的参数 k 为 6, α 为 2 200, 因此, 选取这两个值作为 VMD 算法的最优输入参数值。

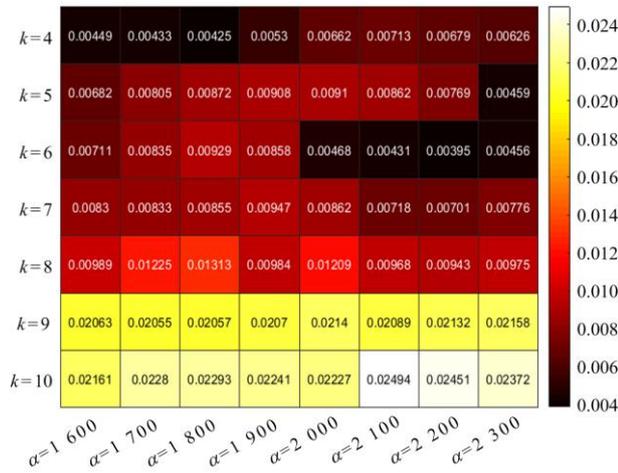


图 1 VMD 网格搜索优化结果可视化
Fig. 1 Visualization of GS-VMD

2.2 ARIMA 模型确定网络输入维数

在建立神经网络模型的时候, 需要先确定网络的拓扑结构, 其中网络隐含层神经元个数通常采用公式经验法^[29]、误差迭代寻优法^[30]来确定; 对于时间序列预测问题, 网络的输出维数通常设定为 1。而对于网络输入维数的确定方法, 则常采用相空间重构^[30]或偏向关函数^[31](Partial Autocorrelation Function, PACF), 但这两种方法均存在一些问题。如前者计算过程较为复杂, 需要耗费较多时间; 而后者需要通过人为观察 PACF 图来确定维数, 缺乏自适应性。因此, 为使确定网络输入维数的方式具备自适应性且无需耗费过多的时间, 本文提出运用 ARIMA 模型来确定神经网络的输入维数。

对三组风速数据经 GS-VMD 分解后的各分量依次建立 ARIMA 模型, 模型参数如表 1 所示。以 10 min 风速数据的 IMF₃ 为例说明本文预测模型输入变量的构成。如图 2 所示, 本文模型采用超前 1 步预测的策略, 以连续 4 个时刻的历史风速值作为模型的输入预测下一时刻的风速值, 图中变量 Y 即为模型的预测值。

表 1 各序列 ARIMA 建模结果及网络输入维数的确定

Table 1 Results of ARIMA and the determination of network input dimensions

风速数据	序列名称	是否平稳	参数 d 阶数	参数 p 阶数	参数 q 阶数	输入维数
10 min	IMF ₁	否	1	5	5	6
	IMF ₂	是	0	5	5	5
	IMF ₃	是	0	4	5	4
	IMF ₄	是	0	5	5	5
	IMF ₅	是	0	3	5	3
	IMF ₆	是	0	5	5	5
1 h	IMF ₁	是	0	4	5	4
	IMF ₂	是	0	4	5	4
	IMF ₃	是	0	3	5	3
	IMF ₄	是	0	5	5	5
	IMF ₅	是	0	5	5	5
2 h	IMF ₁	是	0	5	5	5
	IMF ₂	是	0	4	5	4
	IMF ₃	是	0	5	5	5
	IMF ₄	是	0	4	5	4
	IMF ₅	是	0	5	5	5

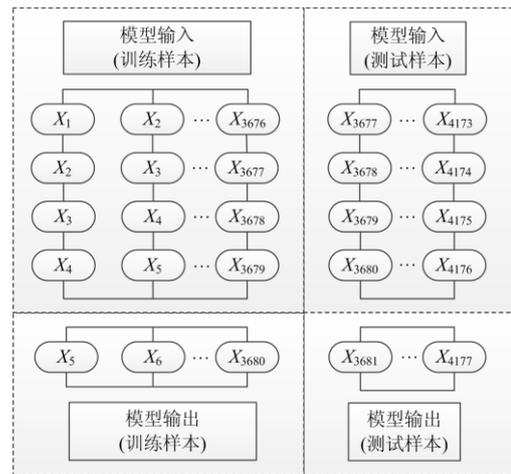


图 2 预测模型的输入变量构成

Fig. 2 Input variables of the prediction model

2.3 基于粒子群优化的极限学习机

粒子群优化算法是一种群智能优化算法, 基于“种群”和“进化”的概念, 通过个体间的协作与竞争, 实现复杂空间最优解的搜索。

由于初始连接权值和偏置值随机设定所带来的偏差, 极限学习机常常出现预测结果不稳定的问题^[32-33]。为提高 ELM 模型的鲁棒性及预测准确性, 本文采用粒子群算法对 ELM 模型中的初始参数进行优化。PSO-ELM 建模步骤如下。

1) 载入风速数据。对数据进行归一化处理, 并

区分训练集以及测试集。

2) 确定 PSO-ELM 模型的拓扑结构。首先, 建立风速序列的 ARIMA 模型, 根据 AIC 值最小原则选取最佳的定阶参数作为网络的输入维数, 建立一个具有 $p+d$ 个输入节点、1 个输出节点的网络。而后, 通过迭代寻优的方式确定网络最佳隐含层个数, 对采样间隔为 10 min 的风速数据进行仿真实验, 其寻优结果如图 3 所示, 可知当迭代次数为 22 时, 网络的误差最小, 因此可确定隐含层神经元个数为 22。网络激活函数选择的是 Sigmoid 函数。

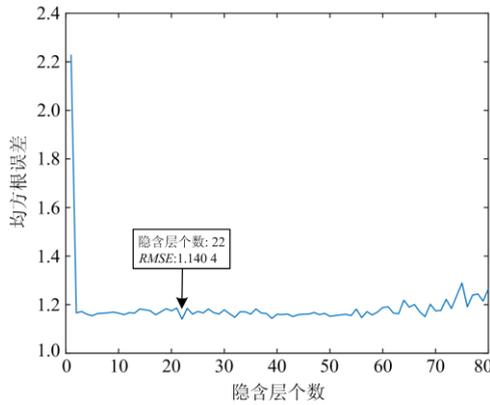


图 3 PSO-ELM 模型隐含层神经元个数的确定

Fig. 3 Determination of hidden layer number of PSO-ELM

3) 初始化粒子群。优化的种群由 ELM 的输入层-隐含层的权值 w_1 , 隐含层的偏置值 b 组成。群体规模 N 为 10, 最大迭代次数为 50, 粒子维数为 39; 粒子速度最大值为 1, 最小值为-1; 粒子位置最大值为 5, 最小值为-5; 学习因子 c_1 、 c_2 均为 1.5; 以 ELM 训练集的输出误差作为适度值函数, 计算出每个粒子的适度值 fit_i 。

4) 比较与更新。首先, 将每个粒子的适度值 fit_i 分别与个体极值 p_{best} 、全局极值 g_{best} 作比较, 若适度值更小, 则可用其替换个体极值和全局极值; 而后, 通过迭代来更新每个粒子的速度和位置。

5) 判断是否达到最大迭代次数或最小误差, 若达到则迭代停止, 否则将继续迭代。

6) 将优化后得到的初始权值和偏置值代入 ELM 模型的训练中, 在模型训练好后, 将测试集代入模型进行预测并计算预测误差。

2.4 算法流程

本文遵循“分解-组合”的思想, 提出一种基于 GS-VMD、ARIMA 和 PSO-ELM 的自适应风速超短期预测组合模型。如图 4 所示, 该模型的预测流程如下:

1) 利用网格搜索优化的方法来确定 VMD 算法关键参数 k 和 α 的取值, 而后对原始的风速数据进

行 VMD 分解, 获得若干个含不同频率成分的 IMF 分量;

2) 依次对各 IMF 分量建立 ARIMA 模型, 以 AIC 最小准则确定各分量 ARIMA 模型的最优参数, 并以此确定网络的输入维数。

3) 对确定好输入维数的各 IMF 分量, 采用 PSO-ELM 模型依次进行预测, 获得每个分量的预测值;

4) 叠加各个分量的预测值获取最终的风速预测值。

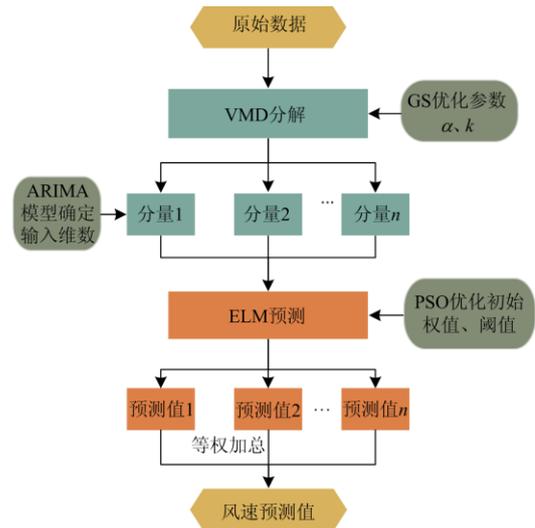


图 4 本文模型的框架

Fig. 4 Framework of the proposed model

2.5 评价指标

为分析各模型风速预测值与实际值之间的误差, 选取平均误差(Mean Error, ME)、平均绝对百分比误差(Mean Absolute Percentage Error, MAPE)、均方根误差(Root Mean Square Error, RMSE)、可决系数 R^2 (Coefficient of determination, R-square) 4 个指标对模型的预测精度以及拟合优度进行评价, 计算公式为

$$ME = \frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i) \quad (15)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{\hat{y}_i - y_i}{y_i} \right| \times 100\% \quad (16)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i)^2} \quad (17)$$

$$R^2 = \frac{\sum_{i=1}^N (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^N (y_i - \bar{y})^2} = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (18)$$

式中: \bar{y} 为真实风速的平均值, $\bar{y} = \frac{1}{N} \sum_{i=1}^N y_i$; y_i 为 i 时刻的风速真实值, \hat{y}_i 为 i 时刻的风速预测值; N 为样本数量。

3 实验结果分析

从天气预报的实践看, 仅利用风速历史数据进行统计学预报, 对未来风速预报的提前时间是有限的, 因此, 为说明本文模型对于风速预报提前时间的定位能力, 选取西班牙某风电场 2020 年 2 月采样间隔为 10 min 以及 3 月采样间隔为 1 h、2 h 的三组风速数据作为研究对象进行超前一步风速预测研究。其中, 采样间隔为 10 min 的风速数据缺失一个样本, 采用临近点线性趋势插值法对该缺失数据进行填充以获取完整的样本。表 2 给出了三组风速数据的描述性统计分析结果, 同时, 将三组风速数据分别划分为训练集和测试集, 分别用于模型的训练和预测, 如图 5 所示。结合图表可发现三组风速序列波动较为剧烈, 均具有明显的非线性非平稳特征。

为说明本文 GS-VMD-ARIMA-PSO-ELM 组合模型的预测效果, 选取以反向传播神经网络模型为代表的机器学习模型、以长短时记忆网络模型(Long Short-Term Memory, LSTM)为代表的深度学习模型、以 ARMA 模型为代表的传统统计模型以及本文所用到的 ELM 模型及其改进模型作为单一基准模型, 另选取引入经验模态分解、集合经验模态分解两种多尺度分解方法的复合模型作为组合基准模型, 与本文模型进行对比, 分别进行提前 10 min、1 h、2 h 的单步预测, 预测效果如图 6 所示, 同时表 3 给出了各模型预测效果的评价指标结果。

表 2 描述性统计分析

Table 2 Descriptive statistical analysis

风速数据	样本类型	样本量	均值	标准差	最大值	最小值
10 min	所有	4 176	7.55	4.22	23.29	0.35
	训练	3 676	7.14	4.13	22.52	0.35
	测试	500	10.60	3.53	23.29	1.89
1 h	所有	744	6.92	3.81	19.56	0.45
	训练	644	6.68	3.81	19.56	0.45
	测试	100	8.49	3.42	13.72	2.15
2 h	所有	372	6.87	3.83	19.56	0.80
	训练	322	6.63	3.83	19.56	0.80
	测试	50	8.44	3.42	13.59	2.15

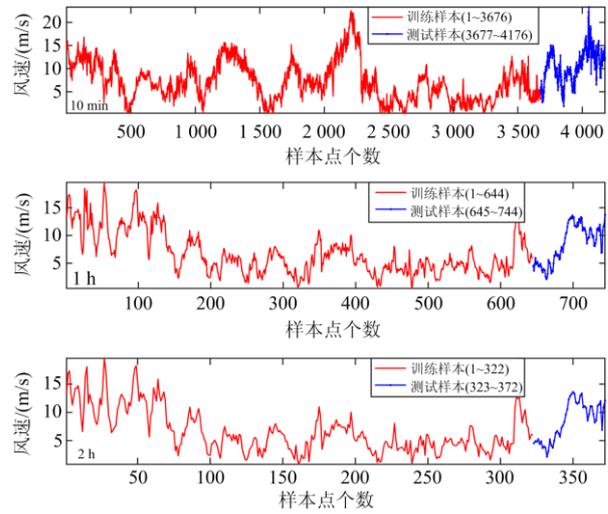


图 5 西班牙风电场实测风速数据
Fig. 5 Real data from Spanish wind farms

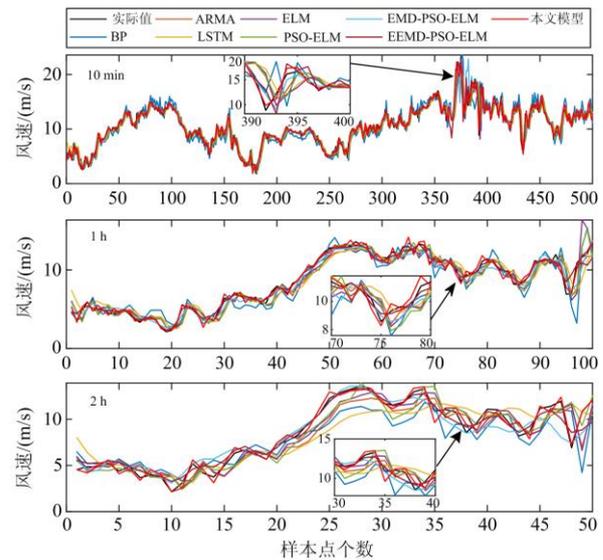


图 6 各模型的预测结果
Fig. 6 Prediction result of each model

从单一模型角度来看, 与 BP、ARMA、LSTM 模型相比, ELM 模型具有更好的预测效果, 同时, 在引入粒子群优化算法后, 该模型的预测效果有了进一步提高。在拟合优度方面, 相较于单一模型中拟合优度较低的 ARMA 模型来说, PSO-ELM 模型的 R^2 提高了 6.36%~9.52%; 在预测精度方面, 相较于单一模型中 $MAPE$ 、 $RMSE$ 、 ME 这三项指标都较大的 BP 模型来说, PSO-ELM 模型的 $MAPE$ 减小了 1.78%~5.59%, $RMSE$ 减小了 0.41 m/s 左右, ME 减小了 0.20 m/s 左右。这说明了利用 ELM 学习速度快以及 PSO 启发式全局寻优的优点能有效提高风速预测的效果。

表 3 各模型的误差评价

Table 3 Errors evaluation of each model

风速数据	模型	R^2 / %	$MAPE$ / %	$RMSE$ / (m/s)	ME / (m/s)
10 min	BP	84.93	11.20	1.51	-1.47
	ARMA	83.04	10.73	1.48	-0.85
	LSTM	86.94	9.72	1.28	-0.08
	ELM	88.25	9.10	1.22	-0.11
	PSO-ELM	89.40	8.95	1.16	-0.10
	EEMD-PSO-ELM	94.47	5.14	0.84	-0.04
	本文模型	97.65	4.44	0.54	0.00
1 h	BP	83.62	14.42	1.42	-0.23
	ARMA	81.36	16.63	1.45	-0.19
	LSTM	88.31	12.97	1.17	-0.12
	ELM	89.23	11.21	1.14	-0.17
	PSO-ELM	90.88	11.04	1.04	-0.13
	EEMD-PSO-ELM	96.58	7.17	0.67	-0.12
	本文模型	98.47	4.35	0.42	-0.01
2 h	BP	75.37	18.52	1.83	-0.60
	ARMA	83.84	15.58	1.42	-0.40
	LSTM	73.11	18.98	1.77	-0.25
	ELM	83.90	14.91	1.37	-0.20
	PSO-ELM	86.36	13.95	1.27	-0.19
	EEMD-PSO-ELM	89.99	11.84	1.13	-0.14
	本文模型	95.84	8.63	0.76	-0.01
本文模型	97.92	5.40	0.49	0.00	

从组合模型角度来看, 由于单一模型缺乏平稳化预处理过程, 致使其无法学习到具有强随机性、非线性的风速数据的内部规律, 预测效果明显差于组合模型, 这说明了在引入多尺度分解的信号处理算法后, 能有效降低原始风速序列的非平稳性和间歇性, 预测结果更加平滑, 能较好地克服样本波动对预测精度的影响。进一步比较三种组合模型的预测效果, 可以发现, 在拟合优度方面, 相较于其余两个组合模型中拟合优度较低的 EMD-PSO-ELM 模型来说, 本文模型的 R^2 提高了 1.89%~3.18%; 在预测精度方面, 相较于其余两个组合模型中 $MAPE$ 值、 $RMSE$ 值和 ME 值都较大的 EMD-PSO-ELM 模型来说, 本文模型的 $MAPE$ 减小了 0.70%~2.82%, $RMSE$ 减少了 0.30 m/s 左右, ME 减少了 0.14 m/s 左右。这说明了 GS-VMD 算法具有较好的降噪能力, 能更好地对原始风速序列进行平稳化处理。

同时, 对各模型的残差序列进行分析, 结果如图 7 所示, 可发现本文模型的残差序列基本在 0 值附近平稳波动, 离群点较少, 总体效果好于其他 7 个基准模型。

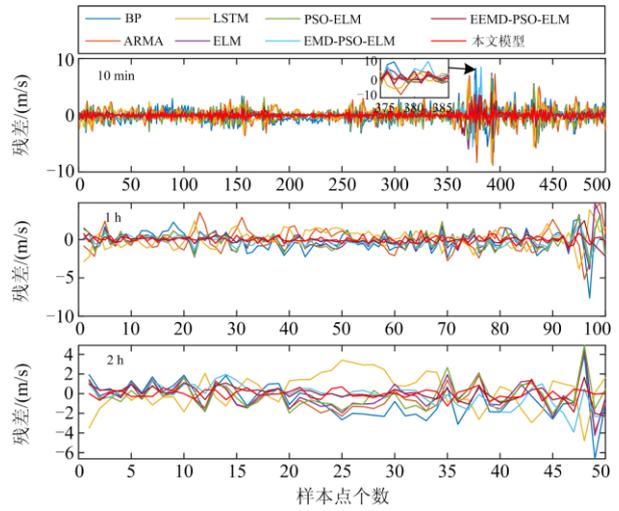


图 7 各模型的残差分析

Fig. 7 Residual analysis of each model

综上, 本文所提出的 GS-VMD-ARIMA-PSO-ELM 模型具有较高的预测精度和拟合优度, 不仅通过自适应分解对原始风速数据进行平稳化处理, 同时也能准确把握分解后各模态分量的变化规律, 预测未来提前时间分别可达到 10 min、1 h 和 2 h, 符合实际风力发电系统的预测需求。

4 结论

本文将 GS-VMD 算法、ARIMA 模型和 PSO-ELM 模型相结合, 遵循“分解-组合”的思路, 提出了一种用于超短期风速预测的自适应模型。通过实例分析, 得出以下结论:

- 1) VMD 算法将具有强非线性及波动性的风速数据分解为多个平稳的 IMF 分量, 可增强风速时间序列的可预报性; 以分量间的正交性为适应度函数, 采用网格搜索优化算法选取合适的分解层数 k 和惩罚因子 α , 可保证各模态分量间的正交性。
- 2) 与传统的相空间重构法和 PACF 法相比, 本文运用 ARIMA 模型来确定神经网络的输入维数可以提高模型的自适应能力, 节省计算时间。
- 3) 运用极限学习机模型能加快风速预测的速度, 在引入粒子群算法优化其初始权值和阈值后, 有效解决了该模型预测结果不稳定的问题, 优化得到的参数更优良, 有效提高了预测的准确性及鲁棒性。

参考文献

[1] 孙铂皓, 汤涌, 叶林, 等. 基于分层分布式模型预测控制的多时空尺度协调风电集群综合频率控制策略[J]. 中国电机工程学报, 2019, 39(1): 155-167, 330.
SU Bohao, TANG Yong, YE Lin, et al. Integrated frequency control strategy for wind power cluster with

- multiple temporal-spatial scale coordination based on H-DMPC[J]. *Proceedings of the CSEE*, 2019, 39(1): 155-167, 330.
- [2] 禹海峰, 潘力强, 吴亚茹, 等. 储能提升含高比例风电电力系统可靠性分析[J]. *电网与清洁能源*, 2020, 36(6): 92-98.
YU Haifeng, PAN Liqiang, WU Yaru, et al. Analysis of energy storage improving the reliability of power system with high proportional wind power[J]. *Power System and Clean Energy*, 2020, 36(6): 92-98.
- [3] 李昊聪, 施嘉昊, 武庆, 等. 含风电接入的电力系统脆弱性分析与量化评估[J]. *电网与清洁能源*, 2020, 36(1): 46-54.
LI Jiongcong, SHI Jiahao, WU Qing, et al. Vulnerability analysis and quantitative evaluation of the power system containing wind power[J]. *Power System and Clean Energy*, 2020, 36(1): 46-54.
- [4] JUNG C, TAUBERT D, SCHINDLER D. The temporal variability of global wind energy long-term trends and inter-annual variability[J]. *Energy Conversion and Management*, 2019, 188(5): 462-472.
- [5] QIAN Z, PEI Y, ZAREIPOUR H, et al. A review and discussion of decomposition-based hybrid models for wind energy forecasting applications[J]. *Applied Energy*, 2019, 235(2): 939-953.
- [6] 陈金富, 朱乔木, 石东源, 等. 利用时空相关性的多位置多步风速预测模型[J]. *中国电机工程学报*, 2019, 39(7): 2093-2106.
CHEN Jinfu, ZHU Qiaomu, SHI Dongyuan, et al. A multi-step wind speed prediction model for multiple sites leveraging spatio-temporal correlation[J]. *Proceedings of the CSEE*, 2019, 39(7): 2093-2106.
- [7] 王鑫, 李慧, 叶林, 等. 考虑风速波动特性的 VMD-GRU 短期风电功率预测[J]. *电力科学与技术学报*, 2021, 36(4): 20-28.
WANG Xin, LI Hui, YE Lin, et al. VMD-GRU based short-term wind power forecast considering wind speed fluctuation characteristics[J]. *Journal of Electric Power Science and Technology*, 2021, 36(4): 20-28.
- [8] 张帅可, 罗萍萍. 基于混合分布模型的风电功率超短期预测误差分析[J]. *电力科学与技术学报*, 2020, 35(5): 111-118.
ZHANG Shuaike, LUO Pingping. Ultra short-time prediction error analysis of wind power based on mixed distribution model[J]. *Journal of Electric Power Science and Technology*, 2020, 35(5): 111-118.
- [9] JUNG J, BROADWATER P. Current status and future advances for wind speed and power forecasting[J]. *Renewable & Sustainable Energy Reviews*, 2014, 31(3): 762-777.
- [10] 王俊, 李霞, 周昔东, 等. 基于 VMD 和 LSTM 的超短期风速预测[J]. *电力系统保护与控制*, 2020, 48(11): 45-52.
WANG Jun, LI Xia, ZHOU Xidong, et al. Ultra-short term wind speed prediction based on VMD and LSTM[J]. *Power System Protection and Control*, 2020, 48(11): 45-52.
- [11] AASIM, SINGH S, MOHAPATRA A. Repeated wavelet transform based ARIMA model for very short-term wind speed forecasting[J]. *Renewable Energy*, 2019, 136(6): 758-768.
- [12] 刘帅, 朱永利, 张科, 等. 基于误差修正 ARMA-GARCH 模型的短期风电功率预测[J]. *太阳能学报*, 2020, 41(10): 268-275.
LIU Shuai, ZHU Yongli, ZHANG Ke, et al. Short-term wind power forecasting based on error correction ARMA-GARCH model[J]. *Acta Energetica Sinica*, 2020, 41(10): 268-275.
- [13] 杨茂, 周宜. 计及风电场状态的风电功率超短期预测[J]. *中国电机工程学报*, 2019, 39(5): 1259-1268.
YANG Mao, ZHOU Yi. Ultra-short-term prediction of wind power considering wind farm status[J]. *Proceedings of the CSEE*, 2019, 39(5): 1259-1268.
- [14] 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, 22(5): 2-9.
- [15] 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 ESN[J]. *Power System Protection and Control*, 2020, 48(12): 90-96.
- [16] 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, 18.
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, 18.
- [17] JASEENA K, KOVOOR B. Decomposition-based hybrid wind speed forecasting model using deep bidirectional LSTM networks[J]. *Energy Conversion and Management*, 2021, 234(6): 113944.
- [18] LIU Mingde, DING Lin, BAI Yulong. Application of hybrid model based on empirical mode decomposition,

- novel recurrent neural networks and the ARIMA to wind speed prediction[J]. *Energy Conversion and Management*, 2021, 233(2).
- [19] YANG B, ZHONG L, WANG J, et al. State-of-the-art one-stop handbook on wind forecasting technologies: an overview of classifications, methodologies, and analysis[J]. *Journal of Cleaner Production*, 2020, 283(6).
- [20] AHMED A, KHALID M. A review on the selected applications of forecasting models in renewable power systems[J]. *Renewable and Sustainable Energy Reviews*, 2019, 100: 9-21.
- [21] 薛禹胜, 陈宁, 王树民, 等. 关于利用空间相关性预测风速的评述[J]. *电力系统自动化*, 2017, 41(10): 161-169.
- XUE Yusheng, CHEN Ning, WANG Shumin, et al. Review on wind speed prediction based on spatial correlation[J]. *Automation of Electric Power Systems*, 2017, 41(10): 161-169.
- [22] 杨正瓴, 冯勇, 熊定方, 等. 基于季风特性改进风电功率预测的研究展望[J]. *智能电网*, 2015, 3(1): 1-7.
- YANG Zhengling, FENG Yong, XIONG Dingfang, et al. Research prospects of improvement in wind power forecasting based on characteristics of monsoons[J]. *Smart Grid*, 2015, 3(1): 1-7.
- [23] 黄进. 基于极值偏移优化的 ARIMA 的短期风速预测[J]. *制造业自动化*, 2018, 40(1): 79-85.
- HUANG Jin. The shifting of extreme short-term wind speed prediction based on the optimization of ARIMA[J]. *Manufacturing Automation*, 2018, 40(1): 79-85.
- [24] 潘震, 黄国勇, 吴漫. 基于参数优化 VMD 和增强多尺度排列熵的单向阀故障诊断[J]. *振动与冲击*, 2020, 39(15): 118-125.
- PAN Zhen, HUANG Guoyong, WU Man. Fault diagnosis of one-way valve based on parameter optimization VMD and enhanced multi-scale arrangement entropy[J]. *Vibration and Impact*, 2020, 39(15): 118-125.
- [25] 徐波, 黎会鹏, 周凤星, 等. 基于自适应 CEEMD 的非平稳信号分析方法[J]. *振动、测试与诊断*, 2020, 40(1): 54-61, 203.
- XU Bo, LI Huipeng, ZHOU Fengxing, et al. Non-stationary signal analysis method based on adaptive CEEMD[J]. *Vibration, Testing and Diagnosis*, 2020, 40(1): 54-61, 203.
- [26] 李兵, 刘明亮, 杨平. EWT 与 GS-SVM 在断路器机械故障诊断中的应用[J]. *哈尔滨工程大学学报*, 2018, 39(8): 1422-1430.
- LI Bing, LIU Mingliang, YANG Ping. Application of EWT and GS-SVM in mechanical fault diagnosis of circuit breakers[J]. *Journal of Harbin Engineering University*, 2018, 39(8): 1422-1430.
- [27] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition[J]. *IEEE Transactions on Signal Processing*, 2014, 62(3): 531-544.
- [28] 许子非, 岳敏楠, 李春. 优化递归变分模态分解及其在非线性信号处理中的应用[J]. *物理学报*, 2019, 68(23): 292-305.
- XU Zifei, YUE Minnan, LI Chun. Application of the proposed optimized recursive variational mode decomposition in nonlinear decomposition[J]. *Acta Physica Sinica*, 2019, 68(23): 292-305.
- [29] 卢格宇. CEEMD 下神经网络的短期风速预测研究[D]. 长沙: 长沙理工大学, 2017.
- LU Geyu. Short-term wind speed prediction of neural networks under CEEMD[D]. Changsha: Changsha University of Science and Technology, 2017.
- [30] 苏盈盈, 李翠英, 王晓峰, 等. 风电场短期风速的 C-C 和 ELM 快速预测方法[J]. *电力系统及其自动化学报*, 2019, 31(7): 76-80, 87.
- SU Yingying, LI Cuiying, WANG Xiaofeng, et al. Short-term wind speed C-C and ELM rapid prediction method for wind farms[J]. *Proceedings of the CSU-EPSCA*, 2019, 31(7): 76-80, 87.
- [31] 陈慧丽. 基于混合优化模型风速预测的研究[D]. 兰州: 兰州大学, 2020.
- CHEN Huili. Research on wind speed prediction based on hybrid optimization model[D]. Lanzhou: Lanzhou University, 2020.
- [32] 王浩, 王艳, 纪志成. 基于 SAIGM-KELM 的短期风电功率预测[J]. *电力系统保护与控制*, 2020, 48(18): 78-87.
- WANG Hao, WANG Yan, JI Zhicheng. Short-term wind power forecasting based on SAIGM-KELM[J]. *Power System Protection and Control*, 2020, 48(18): 78-87.
- [33] 徐睿, 梁循, 齐金山, 等. 极限学习机前沿进展与趋势[J]. *计算机学报*, 2019, 42(7): 1640-1670.
- XU Rui, LIANG Xun, QI Jinshan, et al. Advances and trends in extreme learning machine[J]. *Chinese Journal of Computers*, 2019, 42(7): 1640-1670.

收稿日期: 2021-04-20; 修回日期: 2021-08-28

作者简介:

关永锋(1994—), 男, 硕士研究生, 研究方向为风电场风速与风电功率预测; E-mail: chokfengguan@qq.com

喻敏(1975—), 女, 通信作者, 博士, 讲师, 研究方向为电能质量、风速风功率预测、分形和小波等。E-mail: yufeng3378@163.com

(编辑 葛艳娜)