

基于变分模态分解和蝙蝠算法-相关向量机的短期风速区间预测

范磊¹, 卫志农¹, 李慧杰², Kwok W Cheung³, 孙国强¹, 孙永辉¹

(1. 河海大学 能源与电气学院, 江苏 南京 210098;

2. 阿尔斯通电网技术中心有限公司, 上海 201114;

3. GE Grid Solutions Inc., Redmond 98052, USA)

摘要: 现有的风速预测方法大多是确定性的点预测, 无法描述风速的随机性。针对该问题, 建立基于变分模态分解(VMD)和蝙蝠算法-相关向量机(BA-RVM)的短期风速区间预测模型。对原始风速序列进行变分模态分解获得多个子序列; 采用样本熵(SE)算法对子序列进行重组得到 3 类具有典型特性的分量; 对各分量采用相关向量机算法分别建立预测模型。为进一步提高预测精度、缩小区间范围, 引入蝙蝠算法(BA)对预测模型进行参数优化。将各分量的预测结果进行叠加求和得到一定置信水平下总体的区间预测结果。实际算例结果表明, 与现有方法相比, 所提区间预测方法的预测精度和区间覆盖率更高, 区间宽度更窄。

关键词: 风电; 风速预测; 短期预测; 相关向量机; 变分模态分解; 区间预测

中图分类号: TM 614

文献标识码: A

DOI: 10.16081/j.issn.1006-6047.2017.01.015

0 引言

随着传统化石能源的逐渐减少和环境问题的日益严峻, 可再生能源越来越受到人们的重视, 风能因具有清洁无污染、可循环利用的特点而成为关注的焦点。但是自然风又存在一定的随机性与波动性, 当风电大规模接入电网时, 一旦发生较大的功率波动, 将会影响电网的供需平衡与安全稳定运行。而对风电功率影响最大、最直接的就是风速的变化, 因此准确预测风速对制定合理的发电计划、合理安排系统备用以及提高风电在电网的比重具有战略和实际意义^[1]。

至今为止, 众多的研究者对风速预测的方法展开了长期的研究与探索, 并形成了以时间序列法为代表的传统预测方法^[2]和以神经网络为代表的人工智能方法^[3]。与此同时, 支持向量机等新的机器学习算法也得到了越来越广泛的应用^[4]。然而上述方法一方面受制于自身的固有缺陷, 需具体情况具体分析, 预测效果的鲁棒性较差; 另一方面只能得到点预测结果。而随着风电并网规模的日益扩大, 自然风的随机、波动性将不可忽略, 点预测结果必然无法表征实际风电中潜在的随机性, 从而使决策工作面临一定的风险。鉴于此, 若能在给出确定性点

预测结果的同时描绘出风速波动的区间, 将有利于决策者更合理地安排系统备用, 也更符合坚强智能电网的特点和电力市场的发展需求。

与确定性点预测的方法相比, 目前区间预测仍处于起步阶段。文献[5-6]采用 Bootstrap 重抽样法构造样本, 需要大量处理数据, 耗时较长; 文献[7]通过利用概率密度预测和分位数回归预测 2 种方法对风电功率进行不确定性预测, 取得了较高的预测精度和丰富的概率信息, 但需要预先确定回归模型和分位点, 模型计算量偏大; 文献[8-9]均采用了区间构造的办法, 其中文献[8]提出了以极限学习机 ELM (Extreme Learning Machine) 的点预测为基础, 构造比例系数从而获得短期负荷的区间方法, 文献[9]以集对的形式描述风速的预测区间, 但是其系数的求解都比较繁琐; 文献[10-13]均基于贝叶斯理论的概率预测方法, 可直接得出预测量的期望值及其分布特性, 从而描述结果的区间特性, 总体效果较理想, 但是部分区域存在区间宽度较宽的问题。

针对上述研究现状, 本文在概率预测方法的框架下提出一种基于变分模态分解 VMD (Variational Mode Decomposition) 和蝙蝠算法-相关向量机 BA-RVM (Bat Algorithm-Relevance Vector Machine) 的短期风速区间预测模型。首先, 相关向量机 RVM (Relevance Vector Machine)^[14-15]结合了马尔科夫性质、贝叶斯原理、自动相关决定先验和最大似然等理论, 不仅具有模型稀疏性高、核函数限制少、泛化能力强的优点, 而且在贝叶斯理论和统计学习理论的框架下, 可获得具有概率性的预测结果; 其次, VMD^[16]将原始风速序列分解为多个子序列, 可降低原始数

收稿日期: 2016-01-21; 修回日期: 2016-11-16

基金项目: 国家自然科学基金资助项目(51107032, 61104045, 51277052); 国家高技术研究发展计划(863 计划)资助项目(2013AA050601)

Project supported by the National Natural Science Foundation of China(51107032, 61104045, 51277052) and the National High Technology Research and Development Program of China(863 Program)(2013AA050601)

据的复杂度,且样本熵 SE(Sample Entropy)^[17]算法对子序列的整理可促使其更有典型特征;再者,蝙蝠算法 BA(Bat Algorithm)^[18-19]对 RVM 的参数优化可进一步提高模型的预测精度,缩小区间范围。运用本文模型对风电场的实测风速序列进行提前 1 h 的短期风速区间预测,并采用多种评价指标^[8,20]对本文模型与改进前的模型进行对比分析与效果评估,结果表明本文模型具有较高的预测精度与较窄的区间宽度,具有较高的研究意义和工程实用价值。

1 数据预处理

1.1 VMD

考虑风速的随机性,直接对原始风速序列进行预测的误差较大。目前主要采用的方法是通过对原始数据的分解,降低数据复杂度以提高预测精度,其中比较典型的方法有小波分析、集合经验模态分解 EEMD(Ensemble Empirical Mode Decomposition)、局域均值分解 LMD(Local Mean Decomposition)^[21-23]等。相比 EEMD、LMD 的递归筛选模式,VMD 将信号分解转化非递归、VMD 模式,具有坚实的理论基础。VMD 具有更好的噪声鲁棒性,且通过收敛条件的合理控制,其分量个数也远小于 EEMD 和 LMD;在模态分离方面,VMD 可将频率相近的 2 个纯谐波信号成功分离,文献[16]将该方法应用于轴承的故障诊断,取得了很好的效果。鉴于 VMD 的以上优点,本文采用 VMD 进行风速序列的分解。

1.1.1 VMD 算法原理

VMD 是一种新的信号分解估计方法,其整体框架是变分问题^[24]。其中假设每个模态是具有不同中心频率的有限带宽,目标是使每个模态的估计带宽之和最小。该算法可分为变分问题的构造和求解,具体描述如下。

(1) 变分问题的构造。

假设每个模态是具有中心频率的有限带宽,变分问题描述为寻求 K 个模态函数 $u_k(t)$ ($k=1,2,\dots,K$),使得每个模态的估计带宽之和最小,约束条件为各模态之和等于输入信号 f ,具体构造步骤如下。

a. 对每个模态函数 $u_k(t)$ 的解析信号进行希伯特变换,并最终获得其单边频谱:

$$\left(\delta(t) + \frac{j}{\pi t}\right) u_k(t) \quad (1)$$

$$\delta(t) = \begin{cases} 0 & t \neq 0 \\ \infty & t = 0 \end{cases}, \int_{-\infty}^{+\infty} \delta(t) dt = 1$$

b. 以各模态解析信号的混合-预估中心频率 $e^{-j\omega_k t}$ 为基准将每个模态的频谱调制到相应基频带:

$$\left[\left(\delta(t) + \frac{j}{\pi t}\right) u_k(t)\right] e^{-j\omega_k t} \quad (2)$$

其中, $e^{-j\omega_k t}$ 为中心频率在复平面上的相量描述, ω_k 为中心频率。

c. 计算以上信号梯度的平方 L^2 范数,估计出各模态信号带宽,受约束的变分问题表示如下:

$$\begin{cases} \min_{\{u_k\}, \{\omega_k\}} \left\| \sum_{k=1}^K \left[\left(\delta(t) + \frac{j}{\pi t}\right) u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \\ \text{s.t.} \quad \sum_{k=1}^K u_k = f \end{cases} \quad (3)$$

其中, $\{u_k\} = \{u_1, u_2, \dots, u_K\}$; $\{\omega_k\} = \{\omega_1, \omega_2, \dots, \omega_K\}$ 。

(2) 变分问题的求解。

a. 引入二次惩罚因子 C 和拉格朗日乘法算子 $\theta(t)$,将约束性变分问题变为非约束性变分问题。其中 C 保证信号的重构精度, $\theta(t)$ 保持约束条件的严格性,扩展的拉格朗日表达式如下:

$$\begin{aligned} L(\{u_k\}, \{\omega_k\}, \theta) = & C \sum_{k=1}^K \left\| \left[\left(\delta(t) + \frac{j}{\pi t}\right) u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \\ & \left\| f(t) - \sum_{k=1}^K u_k(t) \right\|_2^2 + \left\langle \theta(t), f(t) - \sum_{k=1}^K u_k(t) \right\rangle \end{aligned} \quad (4)$$

b. VMD 中采用了交替方向乘子法解决以上变分问题,通过交替更新 u_k^{n+1} 、 ω_k^{n+1} 以及 θ^{n+1} (n 表示迭代次数)寻求扩展拉格朗日表达式的鞍点。

其中 u_k^{n+1} 可利用傅里叶等距变换转变到频域:

$$\begin{aligned} \hat{u}_k^{n+1} = \arg \min_{\hat{u}_k, u_k \in X} & \left\{ C \left\| \int \omega \left[1 + \text{sgn}(\omega + \omega_k) \right] \hat{u}_k(\omega + \omega_k) \right\|_2^2 + \right. \\ & \left. \left\| \hat{f}(\omega) - \sum_{k=1}^K \hat{u}_k(\omega) + \frac{\hat{\theta}(\omega)}{2} \right\|_2^2 \right\} \end{aligned} \quad (5)$$

其中, ω 为随机频率; X 为 u_k 的全部可取集合。

将 ω 用 $\omega - \omega_k$ 代替,其非负频率区间积分形式为:

$$\begin{aligned} \hat{u}_k^{n+1} = \arg \min_{\hat{u}_k, u_k \in X} & \left\{ \int_0^{\infty} \left[4C(\omega - \omega_k)^2 \left| \hat{u}_k(\omega) \right|^2 + \right. \right. \\ & \left. \left. 2 \left| \hat{f}(\omega) - \sum_{k=1}^K \hat{u}_k(\omega) + \frac{\hat{\theta}(\omega)}{2} \right|^2 \right] d\omega \right\} \end{aligned} \quad (6)$$

此时,二次优化问题的解为:

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{k=1}^K \hat{u}_k(\omega) + \frac{\hat{\theta}(\omega)}{2}}{1 + 2C(\omega - \omega_k)^2} \quad (7)$$

根据同样的过程,解得中心频率的更新方法:

$$\omega_k^{n+1} = \frac{\int_0^{\infty} \omega \left| \hat{u}_k(\omega) \right|^2 d\omega}{\int_0^{\infty} \left| \hat{u}_k(\omega) \right|^2 d\omega} \quad (8)$$

其中, $\hat{u}_k^{n+1}(\omega)$ 相当于当前剩余量 $\hat{f}(\omega) - \sum_{k=1}^K \hat{u}_k(\omega)$ 的维纳滤波; ω_k^{n+1} 为当前模态函数功率谱的重心;对 $\hat{u}_k(\omega)$ 进行傅里叶逆变换,则其实部为 $\{u_k(t)\}$ 。

1.1.2 VMD 算法流程

a. 初始化参数 $\{u_k^1\}$ 、 $\{\omega_k^1\}$ 、 $\hat{\theta}^1$ 和 n_0 。

b. 根据式(7)和式(8)更新 u_k 和 ω_k 。

c. 更新 θ :

$$\hat{\theta}^{n+1}(\omega) \leftarrow \hat{\theta}^n(\omega) + \tau \left[\hat{f}(\omega) - \sum_{k=1}^K \hat{u}_k^{n+1}(\omega) \right] \quad (9)$$

d. 对给定判别精度 $e > 0$, $\sum_{k=1}^K \frac{\|\hat{u}_k^{n+1} - \hat{u}_k^n\|_2^2}{\|\hat{u}_k^n\|_2^2} < e$, 则停止迭代, 返回步骤 b。

e. 根据给定模态数获得相应模态子序列。

1.2 样本熵

对于 VMD 获得的多个子序列, 若分别建立模型进行预测, 不仅大幅增加计算量, 而且忽略了子序列之间的相关性。若能将具有相关性的序列进行重组, 不仅能有效缩短运算时间, 而且更能突显同类序列的特性^[25]。对于这一问题, 信息论中的熵定律运用最为广泛。例如近似熵可以度量序列的复杂性。但是近似熵的值与数据长度有关, 一致性较差, 且与自身数据段的比较易导致其计算出现偏差。针对近似熵的缺陷, Richman 于 2000 年提出了与近似熵类似, 但精度更好的样本熵理论^[26]。序列的自相似性越高, 样本熵值就越小; 反之, 样本熵值就越大。鉴于此, 本文采用样本熵处理子序列。

样本熵可用 $\text{SampE}_n(N_{\text{um}}, m, v)$ 来表示, 其中 N_{um} 为数据的长度, m 为维数, v 为容限。由于样本熵的具体实现步骤目前已有文献详细说明, 本文不再赘述。当 N_{um} 取有限值时, 样本熵估计值可表示为:

$$\text{SampE}_n(N_{\text{um}}, m, v) = -\ln[B^{m+1}(v)/B^m(v)] \quad (10)$$

SampE_n 取值虽与 m 和 v 的值有关, 但样本熵具有良好的一致性, 其熵值变化的趋势并不受 m 和 v 的影响^[27]。一般 m 取值为 1 或 2, v 为 0.1~0.25 SD, SD 为时间序列的标准差。本文取 $m=2, v=0.15$ SD。

通过样本熵算法重组子序列获得新分量, 显著减少了分量个数, 强化了分量的典型特性。对于新分量可以采用 RVM 算法进行建模预测。

2 基于 BA 的 RVM 模型

2.1 RVM

在支持向量机预测模型的基础上, Michael E. Tipping 基于贝叶斯概率学习理论提出了更实用的 RVM 模型^[28]。与支持向量机相比, RVM 具备支持向量机所没有的如下优点: 相关向量的数目远远小于支持向量, 具有高稀疏性; 仅有核参数的设置, 可节约训练时间; 核函数无需满足 Mercer 条件, 增加了核函数选择的灵活性。

由 RVM 的原理^[28]可知, 在进行点预测时, 仅使用了预测均值这一个量来表示其确定性的预测结果。而使用 RVM 实现区间预测时, 需同时考虑模型的预测均值和方差。具体过程实现如下。

对于给定的训练样本输入集 $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}$ 和对应输出集 $\mathbf{T} = \{t_1, t_2, \dots, t_N\}$, N 为样本数据的个数, RVM 回归模型可定义为:

$$t_i = \sum_{i=1}^N w_i K(\mathbf{x}, \mathbf{x}_i) + w_0 + \varepsilon \quad (11)$$

其中, w_i 为第 i 个输出的对应权值; $K(\mathbf{x}, \mathbf{x}_i)$ 为核函数; \mathbf{x} 为相关向量; ε 为服从 $N(0, \sigma^2)$ 的样本误差。

通过与文献[28]所述点预测类似的计算过程, 可获得 RVM 的预测均值和方差分别为:

$$\begin{cases} y_* = \mathbf{U}^T \boldsymbol{\varphi}(\mathbf{x}_*) \\ \sigma_*^2 = \sigma_{\text{MP}}^2 + \boldsymbol{\varphi}^T(\mathbf{x}_*) \boldsymbol{\Sigma} \boldsymbol{\varphi}(\mathbf{x}_*) \end{cases} \quad (12)$$

式(12)中变量含义请见文献[28]。可以看出, RVM 模型可以同时给出测试点 \mathbf{x}_* 的对应预测均值 y_* 和方差, 因此, RVM 模型能反映预测数据的不确定性, 可以得到一定置信范围内的区间预测。在置信度 $1-\alpha$ 下, 预测结果的置信区间可表示为:

$$[L_b, U_b] = [y_* - z_{\alpha/2} \sigma_*, y_* + z_{\alpha/2} \sigma_*] \quad (13)$$

其中, L_b 和 U_b 分别为预测值的下界和上界; $z_{\alpha/2}$ 为正态分布的双侧 α 分位点。

在采用数据预处理降低数据复杂度、提高预测精度的基础上, 为进一步改善 RVM 模型的预测效果, 需对模型参数进行优化。BA^[29]是一种新的非线性全局优化算法, 其速度和位置的更新与粒子群优化算法有相似过程, 但计算精度和效率优于其他优化算法, 目前已在优化和分类问题中取得了一些应用^[30]。鉴于 BA 优异的寻优特性, 采用该算法对 RVM 模型进行参数优化。

2.2 BA 优化 RVM 参数

采用 BA 对 RVM 模型进行参数优化的具体过程详见文献[15]。BA 的适应度函数为模型训练的平均相对误差, 其优化的目标是找出训练误差最小时的核宽 δ , 算法的输出为训练误差最小时的最佳核宽 δ_{best} 。其适应度函数可表示为:

$$f_{\text{fitness}} = \frac{1}{N_{\text{train}}} \left| \frac{y_{\text{train_fore}} - y_{\text{train_true}}}{y_{\text{train_true}}} \right| \quad (14)$$

其中, N_{train} 为训练样本的个数; $y_{\text{train_fore}}$ 为模型训练输出; $y_{\text{train_true}}$ 为训练集实际输出。

3 基于 VMD 和 BA-RVM 的短期风速区间预测模型

3.1 数据的获取

本文研究的风速数据取自 NREL(the National Renewable Energy Laboratory)的一个风电场, 该风电场位于美国德克萨斯州麦卡米地区, 装机容量 20 MW^[31]。

3.2 使用 VMD 对原始风速序列进行分解

考虑到风速数据的随机性, 直接预测会存在较

大误差。为提高预测精度,需降低数据复杂度,采用 VMD 对原始风速序列进行分解,产生多个子序列。

在进行 VMD 前需事先设定子序列数 K 。而由前期测试可知,对于该风速序列, $K > 5$ 时后续子序列趋于相似,因此本文选择 $K = 5$ 。其他参数如惩罚参数 C 采用 VMD 默认值 2000; τ 选取 0.3 以保证数据分解的保真度。以 2006 年 8 月 1 日的风速序列为例, VMD 效果如图 1 所示,图中时间序列为每 10 min 一点,后同。

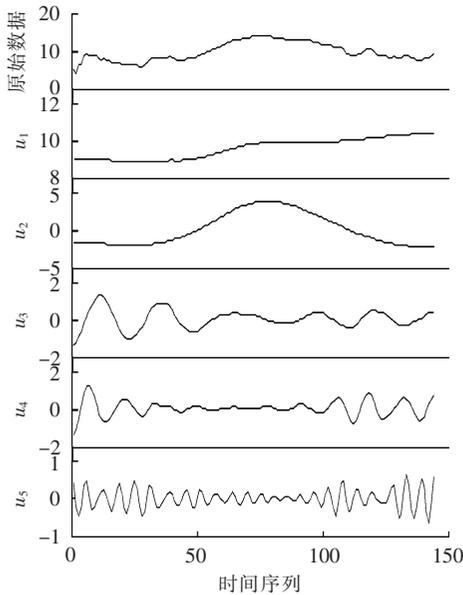


图 1 VMD 算法分解结果图
Fig.1 Results of VMD algorithm

3.3 样本熵重组分量

由图 1 中子序列样本熵值的分布可以发现,部分子序列的样本熵值比较接近。序列的自相似性越高,样本熵值就越小;反之,样本熵值就越大。

因此,使用样本熵对子序列进行重组的规则如下:计算给定序列和与子序列的样本熵值,样本熵值明显低于给定序列的子序列可构成趋势分量,样本熵值明显高于给定序列的子序列可构成随机分量,细节分量的样本熵值介于给定序列样本熵值附近阈值 λ 的范围内, λ 的取值可结合具体数据确定。如图 2 所示,根据子序列样本熵的分布情况,本文中 choice $\lambda = 0.05$,重组完成后的结果如图 3 所示。

分析图 2 和图 3 的特点可以明显发现,趋势分量、细节分量和随机分量具有各自的典型特点。其中趋势分量大致反映原始数据的总体波动趋势;细节分量可表征原始数据的细节波动情况;而随机分量表示其他不可明确描述因素造成的波动情况。以上分类也基本满足自然风的构成情况。VMD 子序列重组新分量的结果如表 1 所示。

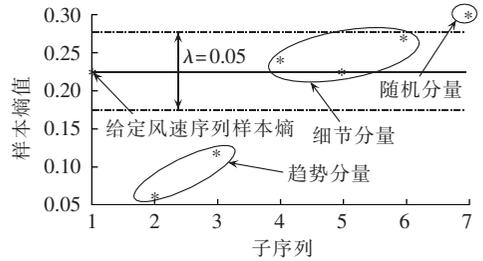


图 2 VMD 各子序列的样本熵值分布
Fig.2 SE distribution of different VMD sub-sequences

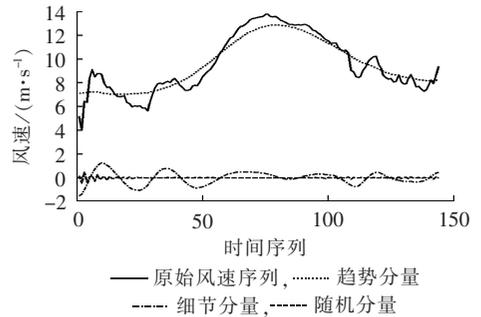


图 3 重组后新分量趋势图

Fig.3 Trend graph of new components after reorganization

表 1 新分量的组成成分

Table 1 Composition of new components

新分量	VMD 分量	新分量	VMD 分量
趋势分量	u_1, u_2	随机分量	u_5
细节分量	u_3, u_4		

为了进一步简化计算、缩小预测区间,本文对趋势分量和细节分量进行点预测,对随机分量实现区间预测。最后将各分量的预测结果进行叠加求和得到一定置信水平下的区间预测结果。

3.4 BA-RVM 模型的参数设定

RVM 是基于核函数的回归预测方法,其核函数实现了多个空间之间的非线性变换。本文采用非线性拟合效果好的高斯核作为模型的核函数,即:

$$K(\mathbf{x}, \mathbf{x}_i) = \exp(-\|\mathbf{x} - \mathbf{x}_i\|^2 / \delta^2) \quad (15)$$

其中, $K(\mathbf{x}, \mathbf{x}_i)$ 为核函数; $\exp(-\|\mathbf{x} - \mathbf{x}_i\|^2 / \delta^2)$ 为高斯核; δ 为核宽,为 RVM 中待优化的参数。本文采用 BA 寻找其最优值。

BA 的初始参数设置如表 2 所示。

表 2 BA 的初始参数设置

Table 2 Initial parameter settings of BA

主要参数	参数值	主要参数	参数值
初始种群规模 s	20	初始响度 A	0.5 dB
脉冲发射速率 r	0.5 次/s	搜索维度 d	2
最大频率 f_{max}	2 Hz	最大迭代次数 N_{iter}	100
最小频率 f_{min}	0		

3.5 区间预测效果的评价指标

区间预测效果的评估方法与点预测有所不同。

点预测方法通常以预测误差(如平均相对误差、均方误差等)的大小作为预测模型的评价指标,误差越小,则预测值越接近实际值,预测精度越高^[20]。

本文采用如下指标对区间预测效果进行评价。

a. 期望值平均相对误差 MAPE(Mean Absolute Percentage Error)^[20,31]:

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

其中, N_{fore} 为预测样本的个数; \bar{y}_i^* 为第 i 个预测样本的预测期望值; y_i 为第 i 个预测样本的实际值。MAPE 用于评价预测期望值与实际值之间的偏差,其值越小,预测精度就越高。

b. 区间覆盖率 FICP(Forecasting Interval Coverage Percentage)^[8]:

$$FICP^{(1-\alpha)} = \frac{1}{N_{fore}} \xi^{(1-\alpha)} \times 100\% \quad (17)$$

其中, $FICP^{(1-\alpha)}$ 为区间覆盖率; $\xi^{(1-\alpha)}$ 为置信度 $1-\alpha$ 下实际值落在预测置信区间内的个数。FICP 用于评价区间的可信程度,其值越大,可信度就越高。

c. 区间平均宽度 FIAW(Forecasting Interval Average Width)^[8]:

$$FIAW^{(1-\alpha)} = \frac{1}{N_{fore}} \sum_{i=1}^{N_{fore}} \frac{U(x_i) - L(x_i)}{y_i} \quad (18)$$

其中, $FIAW^{(1-\alpha)}$ 为置信度 $1-\alpha$ 下的区间平均宽度; $U(x_i)$ 为第 i 个预测样本的上界; $L(x_i)$ 为第 i 个预测样本的下界。上式中采用的是相对宽度。FIAW 用于评价预测结果描述不确定信息的能力,其值越小,效果就越好。

3.6 算法流程框图

本文提出了基于 VMD 和 BA-RVM 的短期风速区间预测模型(VMD-BA-RVM 模型),其具体步骤流程如图 4 所示。

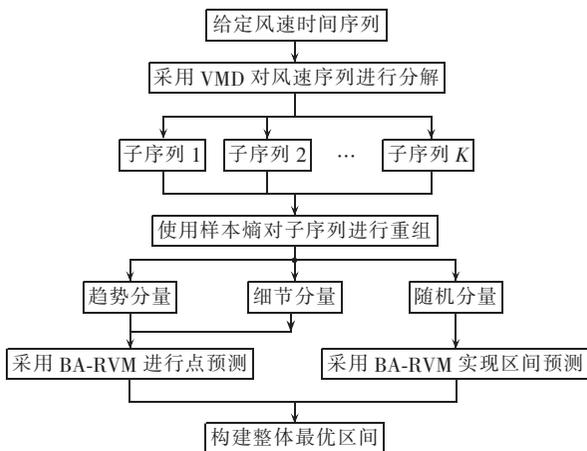


图 4 基于 VMD 和 BA-RVM 的短期风速区间预测框图

Fig.4 Block diagram of short-term wind speed interval prediction based on VMD and BA-RVM

4 算例分析

本文以 MATLAB 2013a 作为平台进行建模。采用美国德克萨斯州麦卡米地区某 20 MW 风电场 2006 年 365 d(每天 144 个点,间隔 10 min)的实际风速数据作为研究对象,进行提前 1 h 的风速区间预测。

为验证 VMD-BA-RVM 模型的区间预测效果,在不同置信水平(本文以 90%、70% 为例)下实现短期风速区间预测,预测结果如图 5、图 6 所示。为了更好地了解预测区间的局部信息,通过对图形的局部放大,进一步显示区间预测效果。以图 5、图 6 中方框框出的范围为例,放大后的区间预测结果分别如图 7、图 8 所示。采用 MAPE、FICP 和 FIAW 指标对区间预测的效果进行评价,部分预测结果及指标结果如表 3 所示。

首先从图 5、6 的区间特点以及表 3 的数据可以得出以下结论:本文模型的短期风速预测期望值能够有效跟随实际值,其上下浮动趋势与实际风速变化情况基本一致;风速实际值绝大部分都落在 90% 置信水平的预测区间之内,少部分落在 70% 置信水平的预测区间之外,区间覆盖率基本符合预先设定的置信度,满足实际情况,体现了本文模型的有效性;90% 置信水平的预测区间宽度明显大于 70% 置

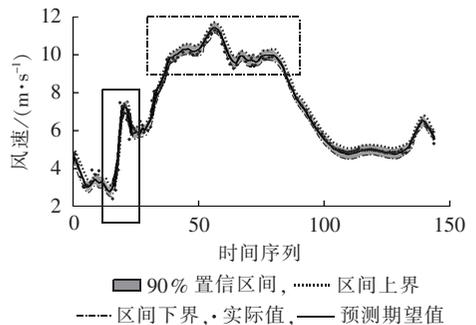


图 5 90% 置信水平下的短期风速区间预测结果
Fig.5 Results of short-term wind speed interval prediction with 90% confidence level

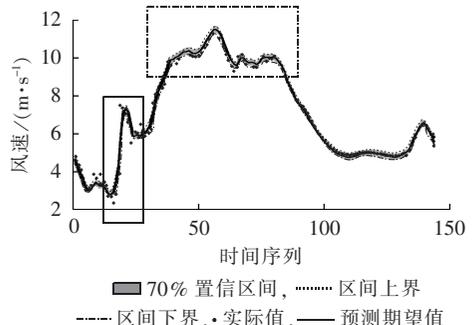


图 6 70% 置信水平下的短期风速区间预测结果
Fig.6 Results of short-term wind speed interval prediction with 70% confidence level

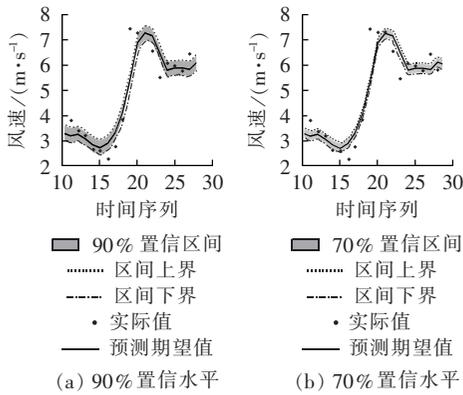


图 7 实线框区域 2 种置信水平下的短期风速区间预测局部结果

Fig.7 Partial results of short-term wind speed interval prediction for solid-line area and two confidence levels

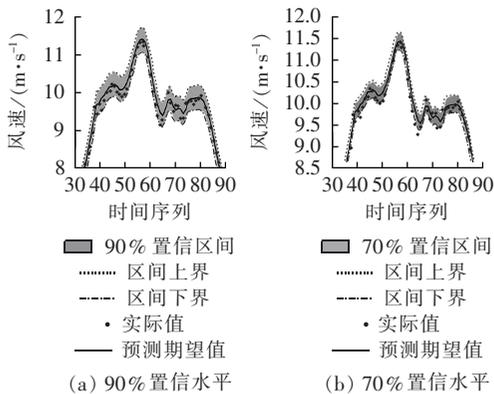


图 8 虚线框区域 2 种置信水平下的短期风速区间预测局部结果

Fig.8 Partial results of short-term wind speed interval prediction for dashed-line area and two confidence levels

表 3 VMD-BA-RVM 模型的区间预测结果
Table 3 Results of interval prediction by VMD-BA-RVM model

(a) 指标				
	置信水平/%	MAPE/%	FICP/%	FIAW
	90	2.61	93.75	0.1390
	70	2.61	72.92	0.0526

(b) 风速				
时刻	风速区间/($\text{m}\cdot\text{s}^{-1}$)		实际风速/ ($\text{m}\cdot\text{s}^{-1}$)	风速预测 期望/($\text{m}\cdot\text{s}^{-1}$)
	90% 置信水平	70% 置信水平		
00:00	[4.18, 5.01]	[4.44, 4.76]	4.72	4.59
00:10	[3.85, 4.68]	[4.11, 4.42]	4.24	4.26
00:20	[3.51, 4.34]	[3.77, 4.08]	4.02	3.92
00:30	[3.19, 4.04]	[3.46, 3.78]	3.47	3.62
⋮	⋮	⋮	⋮	⋮
23:40	[5.38, 6.22]	[5.64, 5.96]	5.90	6.22
23:50	[5.09, 5.93]	[5.35, 5.67]	5.25	5.93

信水平的预测区间宽度。随着置信度的降低, 区间预测的区间宽度降低, 区间覆盖率也随之降低。

由图 7、图 8 相同区域的局部区间预测效果的对比可知, 上述由总体结果得出的结论在局部预测区间

同样适用, 体现了本文模型在总体以及局部上都具有有效性。

为进一步评估本文模型的区间预测效果, 将本文模型与改进前模型(如标准 RVM 模型、BA-RVM 模型、EEMD-RVM 模型)以及现有参考文献模型(EEMD-QPSO-ELM 模型)的预测结果分别进行比较, 并采用 MAPE、FICP、FIAW 指标以及运行时间 t 对区间预测的效果进行评价, 90% 置信水平下的指标评价结果如表 4 所示。

表 4 各预测模型的指标评价结果

Table 4 Results of index assessment for different forecasting models

模型类型	MAPE/%	FICP/%	FIAW	t/s
标准 RVM	3.73	94.44	0.2282	28
BA-RVM	3.67	94.16	0.2166	62
EEMD-RVM	3.71	94.12	0.1938	124
VMD-BA-RVM	2.61	93.75	0.1390	161
EEMD-QPSO-ELM	3.27	90.89	0.1497	207

由表 4 中各模型的指标结果可以得出以下结论: 总体上看, 本文模型的预测误差最小, 区间宽度最窄, 区间覆盖率与运行时间也处于中上水平, 模型的区间预测效果较为理想; 与改进前模型相比, 本文模型的预测误差与区间宽度都得到了明显改善, 虽然区间覆盖率有所下降, 但是仍满足指标要求, 且这是区间宽度变窄的必然结果, 运行时间虽有所延长, 但基本满足工程实际要求; 与现有参考文献模型相比, 本文模型的预测精度和区间覆盖率较高, 区间宽度较窄, 运行时间明显缩短。综上所述, 本文所提的 VMD-BA-RVM 模型可实现短期风速的区间预测, 且预测效果较好。

5 结论

本文提出了一种基于 VMD 和 BA-RVM 的短期风速区间预测方法。首先为降低数据复杂度, 采用 VMD 算法将风速序列分解为多个具有不同中心频率的子序列, 并采用样本熵算法将子序列进行重组获得趋势分量、细节分量以及随机分量; 然后采用 RVM 模型对趋势、细节分量进行点预测, 对随机分量实现区间预测; 为进一步提高预测精度, 缩小区间范围, 采用 BA 对 RVM 模型参数进行优化; 最后将各分量的预测结果进行叠加得到一定置信水平下的总的区间预测结果。算例分析结果表明: 与点预测相比, 本文方法的预测精度较高; 与现有区间预测方法相比, 本文方法的区间覆盖率较高、区间宽度较窄, 总体预测效果较为理想。因此, 本文所提模型对适用工程实际问题与改善其他新能源出力预测(如风电功率、光伏出力等)的效果具有较好的参考价值 and 指导意义。

参考文献:

- [1] 史宇伟,潘学萍. 计及历史气象数据的短期风速预测[J]. 电力自动化设备,2014,34(10):75-80.
SHI Yuwei,PAN Xueping. Short-term wind speed forecasting considering historical meteorological data[J]. Electric Power Automation Equipment,2014,34(10):75-80.
- [2] 王娟娟,赵闻蕾,王兴强,等. 基于 Johnson 分布直接转换法的风速预测[J]. 电力自动化设备,2014,34(6):20-24.
WANG Juanjuan,ZHAO Wenlei,WANG Xingqiang,et al. Wind speed prediction based on Johnson direct transformation[J]. Electric Power Automation Equipment,2014,34(6):20-24.
- [3] 吴俊利,张步涵,王魁. 基于 Adaboost 的 BP 神经网络改进算法在短期风速预测中的应用[J]. 电网技术,2012,36(9):221-225.
WU Junli,ZHANG Buhuan,WANG Kui. Application of Adaboost-based BP neural network for short-term wind speed forecast[J]. Power System Technology,2012,36(9):221-225.
- [4] 陈盼,陈皓勇,叶荣,等. 基于小波包和支持向量回归的风速预测[J]. 电网技术,2011,35(5):177-182.
CHEN Pan,CHEN Haoyong,YE Rong,et al. Wind speed forecasting based on combination of wavelet packet analysis with support vector regression[J]. Power System Technology,2011,35(5):177-182.
- [5] 党宏涛,杜祖良,任宏文,等. 基于 Bootstrap 方法的平台惯导系统标定参数重复性区间预测[J]. 中国惯性技术学报,2013,21(3):411-414.
DANG Hongtao,DU Zuliang,REN Hongwen,et al. Repeatability interval prediction for calibrated parameters of INS based on Bootstrap method[J]. Journal of Chinese Inertial Technology,2013,21(3):411-414.
- [6] 王焱,汪震,黄民翔,等. 基于 OS-ELM 和 Bootstrap 方法的超短期风电功率预测[J]. 电力系统自动化,2014,38(6):14-19.
WANG Yan,WANG Zhen,HUANG Minxiang,et al. Ultra-short-term wind power prediction based on OS-ELM and Bootstrap method[J]. Automation of Electric Power Systems,2014,38(6):14-19.
- [7] JUBAN J,FUGON L,KARINIOTAKIS G. Probabilistic short-term wind power forecasting based on kernel density estimators[C]//European Wind Energy Conference. Milan,Italy:European Wind Energy Association,2007:7-10.
- [8] 李知艺,丁剑鹰,吴迪,等. 电力负荷区间预测的集成极限学习机方法[J]. 华北电力大学学报,2014,41(2):78-88.
LI Zhiyi,DING Jianying,WU Di,et al. An ensemble model of the extreme learning machine for load interval prediction[J]. Journal of North China Electric Power University,2014,41(2):78-88.
- [9] 郭钰锋,孙頔,于继来,等. 集对分析理论在风电场风速区间预测中的应用[J]. 电力系统自动化,2014,38(2):6-10.
GUO Yufeng,SUN Di,YU Jilai,et al. Application of set pair analysis in wind speed interval prediction for wind farms[J]. Automation of Electric Power Systems,2014,38(2):6-10.
- [10] 罗孝辉,童晓阳. 计及可信度的变结构贝叶斯网络电网故障诊断[J]. 电网技术,2015,39(9):2658-2664.
LUO Xiaohui,TONG Xiaoyang. Structure-variable Bayesian network for power system fault diagnosis considering credibility[J]. Power System Technology,2015,39(9):2658-2664.
- [11] 董雷,周文萍,张沛,等. 基于动态贝叶斯网络的光伏发电短期概率预测[J]. 中国电机工程学报,2013,33(增刊):38-45.
DONG Lei,ZHOU Wenping,ZHANG Pei,et al. Short-term photovoltaic output forecast based on dynamic Bayesian network theory[J]. Proceedings of the CSEE,2013,33(Supplement):38-45.
- [12] 孙斌,姚海涛,刘婷. 基于高斯过程回归的短期风速预测[J]. 中国电机工程学报,2012,32(29):104-109.
SUN Bin,YAO Haitao,LIU Ting. Short-term wind speed forecasting based on Gaussian process regression model[J]. Proceedings of the CSEE,2012,32(29):104-109.
- [13] 甘迪,柯德平,孙元章,等. 基于集合经验模态分解和遗传-高斯过程回归的短期风速概率预测[J]. 电工技术学报,2015,30(11):138-147.
GAN Di,KE Deping,SUN Yuanzhang,et al. Short-term wind speed probabilistic forecasting based on EEMD and coupling GA-GPR[J]. Transactions of China Electrotechnical Society,2015,30(11):138-147.
- [14] 段青,赵建国,马艳. 基于稀疏贝叶斯学习的电力系统暂态稳定评估[J]. 电力自动化设备,2009,29(9):36-40.
DUAN Qing,ZHAO Jianguo,MA Yan. Power systems transient stability assessment based on sparse Bayesian learning[J]. Electric Power Automation Equipment,2009,29(9):36-40.
- [15] 朱永利,尹金良. 组合核相关向量机在电力变压器故障诊断中的应用研究[J]. 中国电机工程学报,2013,33(22):68-74.
ZHU Yongli,YIN Jinliang. Study on application of multi-kernel learning relevance vector machines in fault diagnosis of power transformers[J]. Proceedings of the CSEE,2013,33(22):68-74.
- [16] MOHANTY S,GUPTA K K,RAJU K S. Comparative study between VMD and EMD in bearing fault diagnosis[C]//International Conference on Industrial and Information Systems (ICIIS). [S.l.]:IEEE,2014:1-6.
- [17] ZHANG Guoyong,WU Yonggang,WONG K P,et al. An advanced approach for construction of optimal wind power prediction intervals[J]. IEEE Transactions on Power Systems,2015,30(5):2706-2715.
- [18] 黄光球,赵魏娟,陆秋琴. 求解大规模优化问题的可全局收敛蝙蝠算法[J]. 计算机应用研究,2013,30(5):1323-1328.
HUANG Guangqiu,ZHAO Weijuan,LU Qiuqin. Bat algorithm with global convergence for solving large-scale optimization problem[J]. Application Research of Computers,2013,30(5):1323-1328.
- [19] SUN Wei,LIU Mohan,LIANG Yi. Wind speed forecasting based on FEEMD and LSSVM optimized by the bat algorithm[J]. Energies,2015,8(7):6585-6607.
- [20] 杨明,范澍,韩学山,等. 基于分量稀疏贝叶斯学习的风电场输出功率概率预测方法[J]. 电力系统自动化,2012,36(14):125-130.
YANG Ming,FAN Shu,HAN Xueshan,et al. Wind farm generation forecast based on component sparse Bayesian learning[J]. Automation of Electric Power Systems,2012,36(14):125-130.
- [21] 茆美琴,龚文剑,张榴晨,等. 基于 EEMD-SVM 方法的光伏电站短期出力预测[J]. 中国电机工程学报,2013,33(34):17-24.
MAO Meiqin,GONG Wenjian,ZHANG Liuchen,et al. Short-term photovoltaic generation forecasting based on EEMD-SVM combined method[J]. Proceedings of the CSEE,2013,33(34):17-24.
- [22] 王晓兰,王明伟. 基于小波分解和最小二乘支持向量机的短期风速预测[J]. 电网技术,2010,34(1):179-184.
WANG Xiaolan,WANG Mingwei. Short-term wind speed based on wavelet decomposition and least square vector machine[J].

- Power System Technology, 2010, 34(1): 179-184.
- [23] 孙斌, 姚海涛. 基于局域均值分解和多核最小二乘支持向量机的短期风速预测[J]. 太阳能学报, 2013, 34(9): 1567-1573.
- SUN Bin, YAO Haitao. Short-term wind speed based on local mean decomposition and multi-kernel support vector machine [J]. Acta Energetica Solaris Sinica, 2013, 34(9): 1567-1573.
- [24] RAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition [J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.
- [25] 季峰, 蔡兴国, 王俊. 基于混合 Copula 函数的风电功率相关性分析[J]. 电力系统自动化, 2014, 38(2): 1-6.
- JI Feng, CAI Xingguo, WANG Jun. Wind power correlation analysis based on hybrid Copula [J]. Automation of Electric Power Systems, 2014, 38(2): 1-6.
- [26] 向丹, 葛爽. 基于 EMD 样本熵-LLTSA 的故障特征提取方法[J]. 航空动力学报, 2014, 29(7): 1535-1542.
- XIANG Dan, GE Shuang. Method of fault feature extraction based on EMD sample entropy and LLTSA [J]. Journal of Aerospace Power, 2014, 29(7): 1535-1542.
- [27] 张学清, 梁军, 张熙, 等. 基于样本熵和极端学习机的超短期风电功率组合预测模型[J]. 中国电机工程学报, 2013, 33(25): 33-40.
- ZHANG Xueqing, LIANG Jun, ZHANG Xi, et al. Combined model for ultra short-term wind power prediction based on sample entropy and extreme learning machine [J]. Proceedings of the CSEE, 2013, 33(25): 33-40.
- [28] 黄帅栋, 卫志农, 高宗和, 等. 基于非负矩阵分解的相关向量机短期负荷预测模型[J]. 电力系统自动化, 2012, 36(11): 62-66.
- HUANG Shuaidong, WEI Zhinong, GAO Zonghe, et al. A short-term load forecasting model based on relevance vector machine with nonnegative matrix factorization [J]. Automation of Electric Power Systems, 2012, 36(11): 62-66.
- [29] RAMAWAN M K, OTHAM Z, SULAIMAN S I, et al. A hybrid bat algorithm artificial neural network for grid-connected photovoltaic system output prediction [C] // IEEE, International Power Engineering and Optimization Conference. [S.l.]: IEEE, 2014: 619-623.
- [30] WANG Gaige, CHANG Bao, ZHANG Zhaojun. A multi-swarm bat algorithm for global optimization [C] // Congress on Evolutionary Computation (CEC). [S.l.]: IEEE, 2015: 480-485.
- [31] 张露, 卢继平, 梅亦蕾, 等. 基于不同优化准则的风电功率预测[J]. 电力自动化设备, 2015, 35(5): 139-145.
- ZHANG Lu, LU Jiping, MEI Yilei, et al. Wind power forecasting based on different optimization criteria [J]. Electric Power Automation Equipment, 2015, 35(5): 139-145.

作者简介:



范磊

范磊(1991—),男,江苏常州人,硕士研究生,研究方向为电力系统负荷预测(**E-mail**: fl_hohai@163.com);

卫志农(1962—),男,江苏江阴人,教授,博士研究生导师,博士,研究方向为电力系统运行分析与控制、输配电系统自动化等(**E-mail**: wzn_nj@263.net);

李慧杰(1969—),女,上海人,工程师,硕士,研究方向为新能源技术(**E-mail**: lily2.

li@alstom.com);

Kwok W Cheung(1961—),男,美国华盛顿人,教授,博士,研究方向为电力市场管理与新能源技术(**E-mail**: kwok.cheung@alstom.com);

孙国强(1978—),男,江苏江阴人,副教授,博士,研究方向为电力系统运行分析、新能源发电等(**E-mail**: hhsunguoqiang@163.com);

孙永辉(1980—),男,河南平顶山人,教授,博士,研究方向为电力系统运行分析与控制、负荷预测等(**E-mail**: Sunyonghui168@163.com)。

Short-term wind speed interval prediction based on VMD and BA-RVM algorithm

FAN Lei¹, WEI Zhinong¹, LI Huijie², Kwok W Cheung³, SUN Guoqiang¹, SUN Yonghui¹

(1. College of Energy and Electrical Engineering, Hohai University, Nanjing 210098, China;

2. ALSTOM GRID Technology Center Co., Ltd., Shanghai 201114, China;

3. GE Grid Solutions Inc., Redmond 98052, USA)

Abstract: Since the existing wind speed prediction methods are mostly of deterministic point forecasting and could not describe the randomness of wind speed, a short-term wind speed interval prediction model based on VMD (Variational Mode Decomposition) and BA-RVM (Bat Algorithm-Relevance Vector Machine) is built. VMD is used to get multiple sub-sequences from the original wind speed sequence, SE (Sample Entropy) algorithm is applied to reorganize these sub-sequences for obtaining three types of typically characteristic components, and RVM algorithm is adopted to build the forecasting model for each component. BA is introduced to optimize the model parameters for further improving the prediction accuracy and reducing the interval range. The overall interval prediction with a certain confidence level is obtained by superimposing the forecasted results of three components. Results for a practical case show that, compared with the existing methods, the proposed method can get higher forecasting accuracy, bigger interval coverage rate and smaller interval width.

Key words: wind power; wind speed prediction; short-term prediction; RVM; VMD; interval prediction