

文章编号:0254-0096(2018)01-0194-09

基于变分模态分解和LSSVM的风电场 短期风速预测

张 妍¹, 韩 璞¹, 王东风¹, 王少蕊²

(1. 华北电力大学自动化系, 保定 071003; 2. 博莱克威奇(北京)工程设计有限公司, 北京 100022)

摘 要: 针对风速序列的随机性和非平稳性带来的难以准确预测的问题,提出一种基于变分模态分解和最小二乘支持向量机的风速预测模型。首先利用变分模态分解将风速序列分解为一系列限带内禀模态函数以降低其非平稳性对预测性能的影响,然后对各模态分别建立最小二乘支持向量机预测模型,并利用改进的差分进化算法对其关键核参数寻优,最后将各子序列预测结果叠加组合得到最终风速预测值。实例研究表明,所提出的预测模型在短期风速预测上有较高的预测精度。

关键词: 风速预测; 支持向量机; 差分进化; 变分模态分解; 风电场

中图分类号: TM614

文献标识码: A

0 引 言

作为一种无污染的可再生能源,风能的开发利用在国内外均得到高度重视,而风电的间歇性、随机性和不可控制性,使其对电网的稳定运行带来安全隐患。为充分利用有效的风能资源,对风速和风电功率进行预测是大型风电场并网运行的先决条件。文献[1]指出,若短期风速预测的准确率在10%以内,能提高发电量30~100 MW,因此,准确的风速预测可有效提高风能资源的利用效率和风电场的运行效益。

近年来,国内外学者提出多种风速预测和风电功率预测方法。其中研究表明,对风速时间序列采用信号分析方法进行数据预处理可降低风速非平稳性对预测结果的影响,基于信号分析方法的分解-重构预测模型得到越来越多的关注^[2-6]。风速数据分解方法主要有:小波分析及小波包变换^[2,3]、经验模态分解(empirical mode decomposition, EMD)^[4]、集合经验模态分解(ensemble empirical mode decomposition, EEMD)^[5]和局部均值分解(local mean decomposition, LMD)^[6]等。其中,小波分析具有良好的时频局域化特性,但分解效果取决于基函

数的选择,自适应性差;EMD自适应性强,但存在端点效应和过包络等问题^[7];LMD的迭代次数少,端点效应较轻,但判断纯调频信号的条件需要试凑,若滑动跨度选择不当,会引起函数不收敛,导致过平滑,影响算法精确度^[8];EEMD是EMD的改进方法,通过噪声辅助对信号进行分析,减弱了模态混叠现象的影响,已被证明在很多应用中优于其他信号处理方法^[9,10]。

变分模态分解(variational mode decomposition, VMD)是一种新的信号分解方法,相比于EMD、EEMD和LMD的递归筛选模式,VMD将信号转化为非递归、变分模态分解模式,其实质是多个自适应维纳滤波组,表现出更好的噪声鲁棒性^[11]。文献[12,13]将该方法用于故障诊断并取得了很好的效果。本文采用VMD对风速序列数据进行预处理,将其分解为一系列有限带宽的子序列以降低风速原始序列的复杂性和非平稳性,对每个子序列建立最小二乘支持向量机(LSSVM)预测模型,并用改进的差分进化算法对LSSVM模型的核参数寻优,最后将预测结果组合重构作为风速预测值。应用本文模型对内蒙古某风电场实际采集的风速序列进行短期风速预测,仿真结果验证该方法的有效性。

收稿日期: 2017-03-17

基金项目: 中央高校基本科研业务费专项资金(2014MS139)

通信作者: 张 妍(1980—),女,博士研究生、讲师,主要从事风速预测和风电功率预测方面的研究。zhangyan_07@126.com

1 变分模态分解

1.1 VMD原理

VMD 可把复杂信号分解为 K 个调幅调频信号, 是一种可预设尺度的非平稳信号处理方法, 可用于风速时间序列分析。VMD 在获取各分量信号时, 完全摒弃了 EMD 利用循环筛选的处理手段, 通过迭代搜寻变分模型的最优解来确定每个模态函数的中心频率和带宽, 最后自适应地分解信号的频带, 得到预设尺度数 K 个限带内禀模态函数 (band-limited intrinsic mode function, BIMF), 是一种完全非递归的信号分解方法。

变分模态分解的整体框架是变分问题, 主要包括构造变分问题及其求解^[11]。将风速数据序列看成非平稳信号 f , 变分问题描述为寻求 K 个模态函数 $u_k(t) (k=1, 2, \dots, K)$, 每个模态均具有中心频率的有限带宽, 使得每个模态的带宽估计之和最小, 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:

1) 对每个模态函数 $u_k(t)$, 通过 Hilbert 变换计算其解析信号, 得到其单侧频谱。

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

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

2) 对每个模态函数 $u_k(t)$, 通过对其对应的中心频率 ω_k 的指数项混叠, 将每个模态的频谱调制到相应基频带。

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

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

3) $u_k(t)$ 的带宽可由以上调制信号的高斯平滑法估计, 即计算其梯度的平方 L^2 范数, 其求解可表示为带约束条件的变分问题。

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

式中, $\{u_k\} = \{u_1, \dots, u_K\}$, $\{\omega_k\} = \{\omega_1, \dots, \omega_K\}$ 。

对该变分问题的求解如下:

①引入增广拉格朗日函数, 将约束性变分问题

转化为非约束性变分问题。

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \alpha \sum_{k=1}^K \left\| \left(\delta(t) + \frac{j}{\pi t} \right) \cdot u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_{k=1}^K u_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_{k=1}^K u_k(t) \right\rangle \quad (4)$$

式中, α ——二次惩罚因子; $\lambda(t)$ ——拉格朗日乘法算子。

②通过交替更新 u_k^{n+1} 、 ω_k^{n+1} 和 λ_k^{n+1} (n 表示迭代次数) 寻求式(4)的最优解。其中, u_k^{n+1} 由式(5)求得。

$$u_k^{n+1} = \arg \min_{u_k \in X} \left\{ \alpha \left\| \left(\delta(t) + \frac{j}{\pi t} \right) \cdot u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_{i=1}^K u_i(t) + \frac{\lambda(t)}{2} \right\|_2^2 \right\} \quad (5)$$

式中, X —— u_k 的全部可取集合。

③利用傅里叶等距变换将式(5)变换到频域, 求得二次优化问题的解, 见式(6)。

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (6)$$

④ ω_k^{n+1} 的最小值求解同理, 将中心频率更新问题变换到频域, 即:

$$\omega_k^{n+1} = \arg \min_{\omega_k} \left\{ \int_0^\infty (\omega - \omega_k)^2 |\hat{u}_k(\omega)|^2 d\omega \right\} \quad (7)$$

解得中心频率的计算结果如式(8)所示。

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

式中, $\hat{u}_k^{n+1}(\omega)$ ——当前剩余量 $\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega)$ 的维纳滤波; ω_k^{n+1} ——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, 其实部即 $\{u_k(t)\}$ 。

1.2 VMD算法流程

- 1) 初始化 $\{\hat{u}_k^1\}$ 、 $\{\omega_k^1\}$ 、 λ^1 , 迭代次数置 1;
- 2) 根据式(6)和式(8)更新 \hat{u}_k 和 ω_k ;
- 3) 根据式(9)更新 λ ;

$$\lambda^{n+1}(\omega) \leftarrow \lambda^n(\omega) + \tau \left[f(\omega) - \sum_k \hat{u}_k^{n+1}(\omega) \right] \quad (9)$$

式中, τ ——噪声容限参数, 当信号中含有强噪声时, 为了达到良好的去噪效果, 可设定 $\tau=0$ ^[11], 但在

实际应用中,考虑到去噪带来的失真问题,本文在多次实验的基础上选取 $\tau=0.3$ 。

4) 给定判别精度 $\varepsilon>0$, 判断式(10)的收敛条件是否满足, 满足则停止迭代, 否则 n 递增为 $n+1$, 返回步骤 2)。

$$\sum_{k=1}^K \left\| \hat{u}_k^{n+1} - \hat{u}_k^n \right\|_2^2 / \left\| \hat{u}_k^n \right\|_2^2 < \varepsilon \quad (10)$$

经 VMD 分解后的序列与风速原始数据序列相比具有更强的规律性, 可提高预测精度。在对风速进行分解的基础上, 应用 LSSVM 进行建模预测, 为了得到更高精度的模型, 需对 LSSVM 的参数进行优化。

2 改进差分进化算法优化 LSSVM

2.1 最小二乘支持向量机

最小二乘支持向量机是支持向量机(support vector machine, SVM)的改进和扩展, 以最小二乘线性系统作为损失函数, 使用等式约束代替常规 SVM 的不等式约束, 将二次规划问题转化为线性方程组的求解问题, 提高了算法的收敛速度^[9]。其回归预测原理如下: 对于样本集 $(x_i, y_i) \in \mathbf{R}^n \times \mathbf{R}$, $i=1, 2, \dots, l$ 。其中, x_i 是第 i 个输入向量, y_i 是第 i 个输出, 非线性映射 $\phi(\cdot)$ 将样本映射到高维特征空间中, 则 LSSVM 的回归模型可以表示为:

$$f(x) = w^T \phi(x) + b \quad (11)$$

式中, w ——特征空间权系数向量; b ——偏置。根据结构风险最小化原理, LSSVM 回归问题可表示为以下约束优化问题:

$$\begin{cases} \min(\frac{1}{2} \|w\|^2 + C \sum_{i=1}^l e_i^2) \\ s.t. \ y_i = w^T \phi(x_i) + b + e_i, \ i=1, 2, \dots, l \end{cases} \quad (12)$$

式中, C ——惩罚因子; e_i ——误差。式(12)可通过拉格朗日乘子法和 KKT 条件求解。

最小二乘支持向量机常用的核函数有线性函数、多项式核函数、感知器核函数和径向基核函数等。径向基核函数是一个普适的核函数, 通过参数的选择, 可适用于任意分布的样本; 同时, 其参数相对较少, 数值限制条件少, 可降低模型的复杂度, 提高训练速度。因此, 本文选择径向基函数作为 LSSVM 核函数, 其表达式为:

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) \quad (13)$$

式中, σ ——核宽度。可见, 在基于径向基核函数的 LSSVM 模型中, 惩罚因子 C 和核宽度 σ 是影响其性能的主要参数。为提高模型的预测精度, 需要对这 2 个参数进行优化。

2.2 改进的差分进化算法

差分进化算法(DE)是 Storn 和 Price 在 1997 年提出的基于种群差异的进化算法, 通过种群内个体间的合作与竞争来实现对优化问题的求解, 本质上是一种实数编码的具有择优思想的进化算法^[14]。标准差分进化算法采用选择、交叉、变异这三种基本操作。本文所采用的改进差分进化算法(IDE)综合了 2 种变异操作算子, 并对变异因子和交叉概率因子进行改进, 使其根据进化代数自适应变化, 以提高算法的初期全局搜索能力和末期局部搜索精度。具体实现过程如下:

1) 种群初始化。假设种群规模为 NP, 所求问题的自变量维数为 D , 当前进化代数为 t , 则第 t 代种群中第 i 个个体表示为:

$$X_{i,t} = (x_{i,t}^1, x_{i,t}^2, \dots, x_{i,t}^D), \ i=1, 2, \dots, NP$$

个体的值域为:

$$\begin{aligned} X_{\min} &= (x_{\min}^1, x_{\min}^2, \dots, x_{\min}^D) \\ X_{\max} &= (x_{\max}^1, x_{\max}^2, \dots, x_{\max}^D) \end{aligned}$$

则初始种群 $X_{i,0}$ 在值域 $[X_{\min}, X_{\max}]$ 内随机产生。

$$X_{i,0} = (x_{i,0}^1, x_{i,0}^2, \dots, x_{i,0}^D), \ i=1, 2, \dots, NP$$

2) 个体评价。计算每个个体 $X_{i,t}$ 的适应度函数值 $f(X_{i,t})$ 。

3) 变异操作。综合 DE/rand/2/bin 和 DE/best/2/bin 两种变异策略, 并引入权重因子 λ , 提出一种新的变异策略如下: 对每个个体 $X_{i,t}$, 随机生成 5 个整数 $r_1, r_2, r_3, r_4, r_5 \in \{1, 2, \dots, NP\}$, 且 $r_1, r_2, r_3, r_4, r_5, i$ 互不相同, 按照式(14)生成变异个体 $V_{i,t+1}$ 。

$$\begin{cases} V_{i,t+1} = \lambda X_{r_5,t} + (1-\lambda) X_{\text{best},t} + \\ \quad F(X_{r_1,t} - X_{r_2,t} + X_{r_3,t} - X_{r_4,t}) \\ \lambda = \frac{T-t}{T} \\ F = (2 - \frac{T}{t}) F_0 \end{cases} \quad (14)$$

式中, $X_{r_5,t}$ ——父代基向量; $X_{\text{best},t}$ ——第 i 代中的最优个体; $X_{r_1,t} - X_{r_2,t}$ 和 $X_{r_3,t} - X_{r_4,t}$ ——父代差分向量; $\lambda \in [0, 1]$ ——权重因子, 根据进化代数自适应变化, T ——最大迭代次数; t ——当前进化代数; $F \in [0, 2]$ ——变异因子; F_0 ——初始值。

可见,改进后的变异过程中, λ 由 0 逐渐变化到 1, 使得 $X_{r_{st}}$ 的权重逐渐变小而 $X_{best,t}$ 的权重逐渐变大; 同时, F 的取值也随着迭代次数增加由大变小。在进化刚开始时, 算法的搜索空间大, 全局搜索能力强; 而在最后阶段, 算法以局部搜索为主, 有利于在最优区域周围进行搜索, 这样可使算法既有较强的全局搜索能力又能保证收敛精度。

4) 交叉操作。利用式(15)对 $X_{i,t}$ 和 $V_{i,t+1}$ 实施交叉操作, 生成实验个体 $U_{i,t+1}$ 。

$$U_{i,t+1} = (u_{i,t+1}^1, u_{i,t+1}^2, \dots, u_{i,t+1}^D), i = 1, 2, \dots, NP$$

$$u_{i,t+1}^j = \begin{cases} v_{i,t+1}^j & \text{rand}_j \leq CR \text{ or } j = \text{rand}n_i \\ x_{i,t}^j & \text{其他} \end{cases} j = 1, 2, \dots, D$$

$$CR = CR_{\max} \times \left(\frac{CR_{\min}}{CR_{\max}} \right)^{1 - \frac{t}{T}} \quad (15)$$

式中, rand_j ——位于 $[0, 1]$ 区间的均匀分布的随机数; $\text{rand}n_i$ —— $\{1, 2, \dots, D\}$ 内随机产生的维数索引号, 保证了 $U_{i,t+1}$ 至少有一维由变异向量 $V_{i,t+1}$ 贡献, 从而避免了与父代个体向量相同, 提高种群多样性; CR ——交叉概率因子; CR_{\min} ——交叉概率因子最小值; CR_{\max} ——交叉概率因子最大值。进化过程中, CR 由最小值逐渐变化到最大值, 以使算法在搜索初期保持种群多样性, 而在后期有较高的收

敛速度。

5) 选择操作。采用“贪婪选择”策略, 经变异及交叉操作后生成的候选个体 $U_{i,t+1}$ 与 $X_{i,t}$ 竞争。

$$X_{i,t+1} = \begin{cases} U_{i,t+1} & f(U_{i,t+1}) < f(X_{i,t}) \\ X_{i,t} & f(U_{i,t+1}) \geq f(X_{i,t}) \end{cases} i = 1, 2, \dots, NP \quad (16)$$

即按式(16)选择适应度函数值最优者作为第 $t+1$ 代个体。

6) 终止检验。如果种群 $X_{i,t}$ 满足终止条件 (LSSVM 预测值和实际值的均方根误差达到某个精度), 或达到最大迭代次数 T , 则输出最优解, 否则转 2)。

在本文中, 应用上述 IDE 算法对 LSSVM 模型的关键参数 $\{C, \sigma\}$ 进行优化选取。

3 VMD-LSSVM 风速预测模型

风速时间序列具有非线性、非平稳性和随机性的特点, 本文提出变分模态分解和最小二乘支持向量机相结合的短期风速预测模型。首先利用变分模态分解对风速序列进行平稳化处理, 将其分解为一系列不同尺度的模态分量, 降低风速序列的复杂度; 然后对各模态分量分别建立 LSSVM 子模型, 并用 IDE 算法对其模型参数进行优化; 最后将各子模型预测的各模态分量的预测值进行叠加, 得到风速预测值。预测流程如图 1 所示。

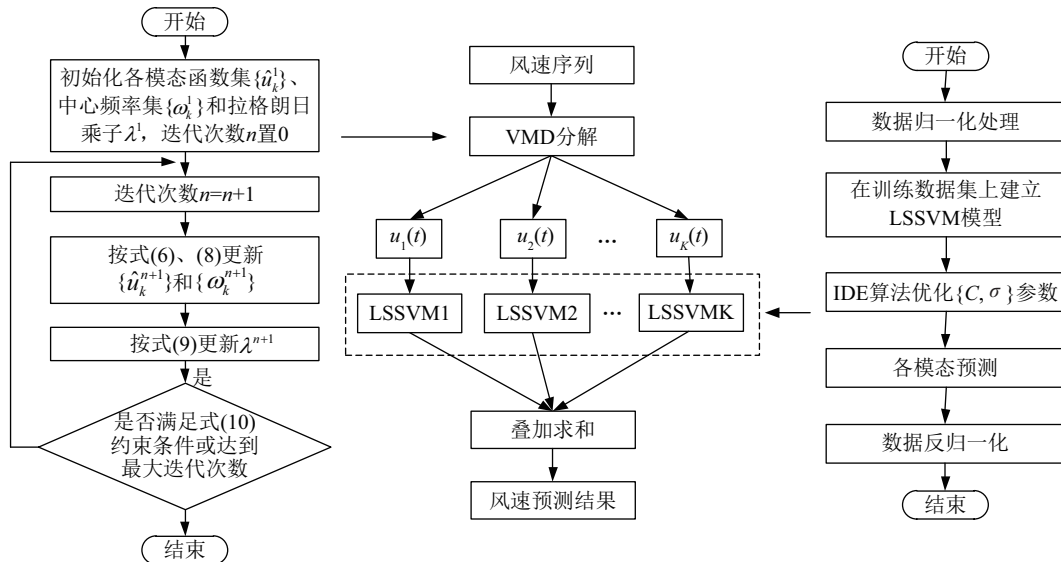


图1 VMD-LSSVM 风速预测流程图

Fig. 1 Flowchart of VMD-LSSVM wind speed prediction

4 算例分析

本文选用内蒙古某风电场 2014 年 1 月份共 31 d 的风速数据对预测模型进行验证。风速序列采样间隔为 10 min, 共 4464 个数据。为研究需要, 对小时平均风速进行提前一步预测。有 2 种预测方案: 一是对 10 min 采样的风速序列进行提前 6 步预测, 再进行小时平均得到预测风速; 二是先对 10 min 采样原始风速序列进行小时平均化处理, 再进行提前 1 步预测。经实验研究, 方案二虽然训练样本多, 但多步预测产生的累积误差导致其预测精度不如方案一, 且耗时较长。故在本文中选用方案二, 即先将风速序列进行小时平均化处理, 处理后的序列共 744 个数据, 如图 2 所示。选择前 30 天的数据共 720 个样本点作为训练集, 第 31 天的数据共 24 个样本点作为预测集。




图2 小时平均风速序列

Fig. 2 Mean hourly wind speed sequence

首先对风速序列进行 VMD 分解, 为防止过分解, 需确定 K 的取值。由于对每个模态的区分主要是中心频率的不同, 本例采用文献[12]中观察中心频率的方法确定 K 的大小。经 VMD 分解得到 BIMF 分量的中心频率呈低频到高频分布, 选择最后 1 个 BIMF 分量的中心频率首次取到最大值时对应的 K 值为分解次数。对 K 从小到大取值, 观察每次分解后各模态中心频率最大值, 当 K 取值为 7 时,

表 1 各模态分量的中心频率

Table 1 Center frequency corresponding to each mode

各模态分量	中心频率/Hz	各模态分量	中心频率/Hz
BIMF1	325.93	BIMF5	48.09
BIMF2	216.02	BIMF6	21.57
BIMF3	143.63	BIMF7	0.14
BIMF4	87.06	—	—

其中心频率首次达到最大值。各模态分量的中心频率如表 1 所示, 可见各中心频率值相差较多, 无相近频率; 对惩罚因子 α 取默认值 2000; τ 取值 0.3 以保证数据分解的保真度。

VMD 分解结果如图 3 所示, 为了对比研究, 用集合经验模态分解方法 EEMD 对风速序列分解, 分解数量是在递归过程中随分解过程自动得出的, 分解为 8 个内禀模态函数 (intrinsic mode function, IMF) 分量和 1 个残差分量 r , 结果如图 4 所示。




图3 VMD分解结果

Fig. 3 Results of VMD




图4 EEMD分解结果

Fig. 4 Results of EEMD

从分解后的分量特征来看,VMD和EEMD分解的各分量都是依次从较高的频率到较低频率。一般认为高频分量是风速的随机影响部分;一些较低频率的分量还具有较强的正弦波动特点,可认为是风速的周期性分量;最后的低频部分是风速的趋势项,它可很清楚地显示出风速的长期走势。从高频分量看,VMD获得的高频分量,其幅值波动均较小,幅值区间大致在 $[-2,2]$ 之间;而EEMD的高频分量幅值波动较大,幅值区间大致为 $[-5,5]$ 。这说明VMD对高频部分的分解比EEMD彻底。

为验证本文提出模型的预测性能,在训练数据集上建立4种模型,在预测数据集上进行提前1步风速预测,并对结果进行对比分析。4种模型风别为:用网格搜索方法对核参数 $\{C, \sigma\}$ 寻优的LSSVM模型;用改进IDE算法对核参数寻优的IDE-LSSVM模型;用EEMD分解后分别建立IDE-LSSVM模型后再重构的EEMD-LSSVM模型;用VMD分解后分别建立IDE-LSSVM模型后再重构的VMD-LSSVM模型。预测评价指标为均方根误差RMSE、平均绝对误差MAE和平均绝对百分比误差MAPE,其定义分别为:

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

$$MAE = \frac{1}{N} \sum_{i=1}^N |x_i - \hat{x}_i| \quad (18)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{x_i - \hat{x}_i}{x_i} \right| \times 100\% \quad (19)$$

式中, x_i —— t 时刻实际值; \hat{x}_i —— t 时刻预测值。式(19)中如果分母为0,则将其设置为非零的极小数,以避免除法出错。各模型预测曲线如图5所示,预测评价指标及算法运行时间 t 如表2所示。




图5 各模型的风速预测曲线

Fig. 5 Wind speed prediction curve of each mode

算法运行环境为: Windows 7 32 位操作系统, Intel core i3 CPU 3.40 GHz, Matlab R2009b。

表2 预测结果对比

Table 2 Comparison of the predicted results

预测模型	RMSE/ $m \cdot s^{-1}$	MAE/ $m \cdot s^{-1}$	MAPE/ %	t / min
LSSVM	0.5739	0.4614	11.23	1.21
IDE-LSSVM	0.4624	0.3717	9.05	4.60
EEMD-LSSVM	0.2832	0.2278	6.35	41.48
VMD-LSSVM	0.1471	0.1207	3.00	32.31

从图5的预测曲线上看,4种模型预测的风速序列均与实际风速变化趋势一致。从表2的预测误差对比来看,IDE-LSSVM的预测精度高于LSSVM,说明核参数优化可提高LSSVM模型预测精度;基于信号分解的EEMD-LSSVM和VMD-LSSVM预测模型,其预测精度均优于直接预测模型,说明信号分解可有效降低风速序列的非平稳特征;而2种基于信号分解的模型中,VMD-LSSVM模型的预测精度比EEMD-LSSVM模型有明显提高,这是由于EEMD高频部分分量由于幅值偏大,预测精度较差,从而影响了整体预测精度,而VMD对高频信号分解更为彻底,降低了高频信号的幅值,使各分量预测精度相差不大,从而集成后的模型精度得到提高。预测精度的提高以牺牲算法运行时间为代价,分解集成模型由于要建立各子模型并分别寻优再求和,故其运行时间明显长于前2个直接预测模型;但VMD-LSSVM模型由于分解后的分量少于EEMD-LSSVM模型,故其运行时间比其略短。

计算各模型在每个预测点上的相对误差百分比 δ_i , 绘制其分布曲线,如图6所示。

$$\delta_i = \frac{|x_i - \hat{x}_i|}{x_i} \times 100\% \quad (20)$$

式中, x_i —— t 时刻实际值;若某时刻其值为零,则将其设置为非零的极小数,以避免除法出错。

从图6可看出,VMD-LSSVM模型的所有预测点相对误差均在10%以下,尤其在风速突变点上预测精度比另外3种模型有明显提高。这表明本文提出的方法在一定程度上能提高短期风速预测的准确性。




图6 相对误差百分比图

Fig. 6 Relative error percentage curve

为进一步验证本文预测方法的泛化能力,选取不同月份(4、7、10月份)的小时平均风速数据分别建立 VMD-LSSVM 模型,并对该月最后 1 天的小时平均风速提前 1 步预测,预测曲线如图 7 所示,误差指标如表 3 所示。可见在不同季节的小时平均风速预测中,本文所提出的预测模型,均能进行准确预测,其预测各点的绝对误差都在 1 m/s 以下。

表3 不同月份预测结果

Table 3 Forecast results for different months

预测月份	$RMSE/m \cdot s^{-1}$	$MAE/m \cdot s^{-1}$	$MAPE/\%$
1	0.1471	0.1207	3.00
4	0.3255	0.2484	3.50
7	0.1894	0.1523	2.56
10	0.1394	0.1294	6.50




图7 不同月份预测曲线

Fig. 7 Forecast curve for different months

5 结 论

本文将变分模态分解用于风电场风速序列的平稳化处理,对分解后的各子序列分别建立最小二乘支持向量机模型,对子序列分别预测后再叠加求和得到风速预测结果。通过仿真实验,得出了以下结论:

1)用 IDE 算法对 LSSVM 参数优化可提高模型预测精度。

2)信号分解后预测再集成的风速预测模型,比直接风速预测模型预测精度高,信号分解可有效降低风速序列的非平稳特征对预测结果的影响。

3)从对风速序列进行分解后的结果来看,VMD 对高频部分的分解比 EEMD 更为彻底,且高频分量幅值波动较小。VMD-LSSVM 模型可有效预测短期风速变化,取得了比 EEMD-LSSVM 模型更好的预测效果。

[参考文献]

- [1] Damousis I G, Dokopoulos P. A fuzzy expert system for the forecasting of wind speed and power generation in wind farms [A]. IEEE Power Industry Computer Applications Conference[C], Sydney, 2001: 63—69.
- [2] Da Liu, Dongxiao Niu, Hui Wang, et al. Short-term wind speed forecasting using wavelet transform and support vector machines optimized by genetic algorithm [J]. Renewable Energy, 2014, 62(2): 592—597.
- [3] 柳 玉, 曾德良, 刘吉臻, 等. 基于小波包变换的最小二乘支持向量机短期风速多步预测和信息粒化预测的研究[J]. 太阳能学报, 2014, 35(2): 214—220.
- [3] Liu Yu, Zeng Deliang, Liu Jizhen, et al. Wavelet packet transform and the least squares support vector machine in research of short-term wind speed multistep prediction and information granulation prediction [J]. Acta Energiæ Solaris Sinica, 2014, 35(2): 214—220.
- [4] Liu Hui, Chen Chao, Tian Hongqi, et al. A hybrid model for wind speed prediction using empirical mode decomposition and artificial neural networks [J]. Renewable Energy, 2012, 48(12): 545—556.
- [5] 常 鹏, 高亚静, 张 琳, 等. 基于 EEMD 与时间序列法的短期风电场功率预测[J]. 电力科学与工程,

- 2012, 28(3): 33—39.
- [5] Chang Peng, Gao Yajing, Zhang Lin, et al. Short-term power forecast of wind farm based on EEMD and time series [J]. Electric Power Engineering, 2012, 28(3): 33—39.
- [6] 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.
- [6] Sun Bin, Yao Haitao. Short-term wind speed forecasting based on local mean decomposition and multi-kernel support vector machine[J]. Acta Energiæ Solaris Sinica, 2013, 34(9): 1567—1573.
- [7] 李天云, 谢家安, 张方彦, 等. HHT在电力系统低频振荡模态参数提取中的应用[J]. 中国电机工程学报, 2007, 27(28): 79—83.
- [7] Li Tianyun, Xie Jiaan, Zhang Fangyan, et al. Application of HHT for extracting model parameters of low frequency oscillations in power systems[J]. Proceedings of the CSEE, 2007, 27(28): 79—83.
- [8] 程军圣, 张 亢, 杨 宇, 等. 局部均值分解与经验模式分解的对比研究[J]. 振动与冲击, 2009, 28(5): 13—16, 201.
- [8] Cheng Junsheng, Zhang Kang, Yang Yu, et al. Comparison between the method of local mean decomposition and empirical mode decomposition[J]. Journal of Vibration and Shock, 2009, 28(5): 13—16, 201.
- [9] 杨德友, 蔡国伟. 基于因散经验模式分解与最小二乘支持向量机的风电场短期风速预测[J]. 东北电力大学学报, 2015, 35(3): 44—49.
- [9] Yang Deyou, Cai Guowei. The short-term wind speed forecasting for wind farm based on EEMD and LS_SVM [J]. Journal of Northeast Dianli University, 2015, 35(3): 44—49.
- [10] 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.
- [10] 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.
- [11] Dragomiretskiy K, Zosso D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531—544.
- [12] 刘长良, 武英杰, 甄成刚. 基于变分模态分解和模糊C均值聚类的滚动轴承故障诊断[J]. 中国电机工程学报, 2015, 35(13): 3358—3365.
- [12] Liu Changliang, Wu Yingjie, Zhen Chenggang. Rolling bearing fault diagnosis based on variational mode decomposition and fuzzy C means clustering [J]. Proceedings of the CSEE, 2015, 35(13): 3358—3365.
- [13] 张 宁, 朱永利, 高艳丰, 等. 基于变分模态分解和概率密度估计的变压器绕组变形在线检测方法[J]. 电网技术, 2016, 40(1): 297—302.
- [13] Zhang Ning, Zhu Yongli, Gao Yanfeng, et al. An on-line detection method of transformer winding deformation based on variational mode decomposition and probability density estimation [J]. Power System Technology, 2016, 40(1): 297—302.
- [14] Storn R, Price K V. Differential evolution-A simple and efficient heuristic for global optimization over continuous spaces [J]. Journal of Global Optimization, 1997, 11(4): 341—359.

SHORT-TERM PREDICTION OF WIND SPEED FOR WIND FARM BASED ON VARIATIONAL MODE DECOMPOSITION AND LSSVM MODEL

Zhang Yan¹, Han Pu¹, Wang Dongfeng¹, Wang Shaorui²

(1. *Department of Automation, North China Electric Power University, Baoding 071003, China;*

2. *BLACK & VEATCH International Company, Beijing 100022, China*)

Abstract: In view of difficulty in accurate forecasting wind speed sequence influenced by randomness and nonstationarity, a wind speed prediction model based on variational mode decomposition (VMD) and least squares support vector machine (LSSVM) is presented. Firstly, the mean hourly wind speed data is decomposed into a series of band-limited intrinsic mode functions (BIMF) using VMD method to decrease the instability of wind speed series. Then the LSSVM forecasting models are established respectively for each mode and the key kernel parameters are optimized using improved differential evolution algorithm. Finally, the wind speed forecasting model is obtained by superposing each predicting subsequence. Case study shows that the proposed forecasting model has relatively high predicting accuracy on short-term wind speed prediction.

Keywords: wind speed prediction; support vector machine; differential evolution; variational mode decomposition; wind farm