

DOI: 10.7667/PSPC170590

基于 CEEMD 和 GWO 的超短期风速预测

王 静, 李维德

(兰州大学数学与统计学院, 甘肃 兰州 730000)

摘要: 风电场风速预测对电力系统的合理调度、安全运行等方面有重大的影响。针对风速时间序列的非线性特征造成其预测精度不佳的问题, 采用基于互补型集成经验模态分解和灰狼优化算法优化支持向量回归机的超短期风速组合预测模型来解决。首先利用该模型对非平稳的风速时间序列进行 CEEMD 分解, 分解为一系列的相对平稳分量。然后对各个分量利用灰狼算法优化 SVR 进行预测。最后, 将每一个分量的预测结果集成输出作为最终的风速预测结果。结果表明, 该预测模型比其他智能算法基准模型预测精度高, 且在风速预测中具有优越性。

关键词: 本征模态函数; 互补型集成经验模态分解; 支持向量回归机; 灰狼优化算法; 超短期风速预测

Ultra-short-term forecasting of wind speed based on CEEMD and GWO

WANG Jing, LI Weide

(School of Mathematics and Statistics, Lanzhou University, Lanzhou 730000, China)

Abstract: Forecasting of wind speed has a big influence on the rational dispatch and safety operation of electric power system. Aiming at the problem that the nonlinear characteristics of wind speed time series cause its poor prediction accuracy, a combined model based on complementary ensemble empirical mode decomposition and a support vector regression machine optimized by Gray Wolf Optimization (GWO) algorithm is used to predict ultra-short-term wind speed. First, the non-stationary wind speed time series is decomposed into a series of relatively stationary components by CEEMD. Then, each component is predicted by SVR optimized by GWO. Finally, the prediction values of each sequence are superimposed as the final prediction of wind speed. The results show that the prediction model is more accurate compared with other intelligent algorithm benchmark models and has superiority in wind speed prediction.

This work is supported by National Natural Science Foundation of China (No. 41571016).

Key words: intrinsic mode function; complementary integrated empirical mode decomposition; support vector regression; gray wolf optimization algorithm; ultra-short-term wind speed prediction

0 引言

近几十年来中国经济迅速发展, 矿物能源的大量消耗以及环境保护措施的欠缺, 导致中国许多地区发生了严重的环境污染。在环保节能的同时还应该致力于寻找新的可再生能源, 具有清洁环保和可持续发展的风能源成为人类关注的焦点。开发风能资源, 风电厂风速预测十分重要^[1]。近年来中国在风电装机容量增大上已取得很大成就, 有效的风速预测可显著提高风电发电效益^[2]。

目前, 国内外风速预测研究主要有基于机理的物理模型预测方法和基于历史数据的统计预测方

法^[3-4]。物理模型预测方法采用实时气象条件进行预测, 但是由于数值气象模型的复杂性和气象预报数据更新频率低, 不适用于短期和超短期风速预测。对于基于历史数据的风速预测方法, 当历史数据仅局限于单个空间位置时, 统计方法只能处理时间序列风速数据的相关性, 常用的方法有时间序列法^[5]、卡尔曼滤波法^[6]、神经网络法^[7]和支持向量机法^[8]等。如果历史数据来自不同空间的位置, 那么就需要挖掘数据间的相关性, 即空间相关性方法^[9-10]。其中, 基于神经网络的预测模型在短期及超短期风速、风电场功率预测领域广泛应用^[11]。然而, 单一的预测模型在预测风速时的精度和泛化能力有一定的局限性, 往往需要与其他技术结合使用。

支持向量回归机的预测效果与其参数紧密相

基金项目: 国家自然科学基金资助(41571016)

关, 已有学者利用粒子群优化算法^[12]、遗传优化算法^[13]和萤火虫优化算法^[14]等人工智能优化算法对单一预测模型进行参数寻优, 从而预测风速。研究表明参数寻优可以提高风速预测的精度, 并且优化算法的全局寻优能力越好则模型预测精度越高。

本文提出一种基于互补型集成经验模态分解和灰狼优化算法优化支持向量回归机的预测模型, 并对重庆某监测站超短期风速进行预测。分析结果表明, 本文提出的预测方法有较高的预测精度。

1 理论基础

1.1 CEEMD 方法原理

1.1.1 EMD 方法原理

经验模态分解(Empirical Mode Decomposition, EMD)是由 Huang 等人^[15]提出的, 它适用于非线性、非平稳的信号处理。EMD 可以基于信号的局部特征, 使任意不同尺度的信号分解产生相对平稳且具有特征尺度的本征模态函数(Intrinsic Mode Function, IMF)。

EMD 假设时间序列由不同的振荡模式同时组成, 并伴有隐藏的内在复杂性。因此将原始序列分解为本征模态函数和残余分量, 如式(1)。

$$x(t) = \sum_{i=1}^m c_i(t) + r_m(t) \quad (1)$$

式中: m 表示 IMF _{s} 的个数; $c_i(t)$ 表示第 i 个 IMF; $r_m(t)$ 表示第 m 个残余分量。

1.1.2 EEMD 方法原理

EEMD 方法是 Wu 和 Huang 等人为改善模态混叠现象所提出的^[16]。该方法在 EMD 的基础上加入高斯白噪声, 使信号在不同的尺度上具有连续性, 有效避免了 EMD 分解过程中由于 IMF 的不连续而造成的信号混叠现象。其具体步骤如下^[17]。

1) 在原始序列 $s(t)$ 中多次加入均值为 0、标准差为常数的高斯白噪声 $n_i(t)$, 即

$$x_i(t) = s(t) + n_i(t) \quad (2)$$

式中, $x_i(t)$ 为第 i 次加入白噪声的信号。

2) 对 $x_i(t)$ 进行 EEMD 分解, 得到 IMF 分量 IMF _{j} 和残余分量 Residual。分解的结果表示为

$$x(t) = \sum_j \text{IMF}_j + \text{residual} \quad (3)$$

$$\text{IMF}_j = \frac{1}{N} \sum_{i=1}^N \text{IMF}_{ij} \quad (4)$$

式中, IMF _{j} 为第 i 次加入白噪声信号分解得到的第 j 个 IMF 分量。

1.1.3 CEEMD 方法原理

Yeh 等^[18]对 EEMD 进行改进, 将随机高斯白噪声以正、负成对的方式加入, 经验证明对于重构信号中的残余辅助噪声具有很好的消除效果。该方法称为互补型集成经验模态分解(Complementary Ensemble Empirical Mode Decomposition, CEEMD)。

CEEMD 主要分为三个步骤。

1) 向原始信号中加入 n 组正、负成对的辅助白噪声, 从而得到包含 $2n$ 个信号的集合。

$$\begin{bmatrix} M_1 \\ M_2 \end{bmatrix} = \begin{bmatrix} 1 & 1 \\ 1 & -1 \end{bmatrix} \begin{bmatrix} S \\ N \end{bmatrix} \quad (5)$$

式中: S 为原始信号; N 为辅助白噪声; M_1 、 M_2 为加入正、负成对白噪声后的信号。

2) 对集合中每个信号进行 EMD 分解, 每个信号得到一组 IMF 分量, 其中第 i 个分量的第 j 个 IMF 分量表示为 c_{ij} 。

3) 多组分量取均值得到分解结果。

$$c_j = \frac{1}{2n} \sum_{i=1}^{2n} c_{ij} \quad (6)$$

式中, c_j 表示分解后最终得到的第 j 个 IMF 分量。

1.2 灰狼优化算法原理

基于新型群智能算法, Mirjalili 等^[19]提出了灰狼优化算法(Grey Wolf Optimizer, GWO)。该算法模拟了自然界中灰狼的等级制度与狩猎行为。Mirjalili 等提出的灰狼算法包含以下几个内容。

1) 社会等级

一般灰狼群体内有严格的等级制度, 如图 1 所示为灰狼等级结构图。整个狼群被分为 4 组。位于金字塔顶端的头狼为 α , 它的职责主要是对捕猎行为作出决策。位于第 2 层的为 β , 当整个狼群缺失 α 时, β 是 α 的接替者。位于第 3 层的是 δ , δ 听从 α 和 β 的指令。最底层的 ω 为一般成员。前三层依次是适应度最好的三组, 并引导狼 ω 向目标搜索。

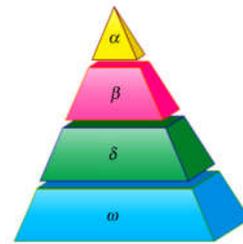


图 1 灰狼等级结构图

Fig. 1 Gray wolf hierarchy structure

2) 包围猎物

在优化过程中, 狼群个体间进行位置更新, 式(7)表示个体间距离, 式(8)表示灰狼更新方式。

$$\bar{D} = |\bar{C} \cdot \bar{X}_p(t) - \bar{X}(t)| \quad (7)$$

$$\bar{X}(t+1) = \bar{X}_p(t) - \bar{A} \cdot \bar{D} \quad (8)$$

式中: \bar{D} 表示个体与猎物间距离; t 表示当前迭代次数; \bar{X} 表示灰狼的位置; \bar{X}_p 表示食物的位置; \bar{A} 、 \bar{C} 被定义为式(9)和式(10)。

$$\bar{A} = 2\bar{a} \cdot \bar{r}_1 - \bar{a} \quad (9)$$

$$\bar{C} = 2\bar{r}_2 \quad (10)$$

式中: \bar{r}_1 、 \bar{r}_2 是[0, 1]的随机向量; \bar{a} 在迭代过程中从 2 线性递减到 0。

3) 狩猎

狼 α 有能力识别猎物并包围它们, 为了在数学上模拟灰狼狩猎行为, 假设灰狼知道一些猎物潜在的信息。在此基础上, 保存目前得到的前三个最佳的位置, 并且搜索代理 ω 必须根据当前三个最佳位置进行更新, 更新过程如下:

$$\bar{D}_\alpha = |\bar{C}_\alpha \cdot \bar{X}_\alpha - \bar{X}|, \quad \bar{D}_\beta = |\bar{C}_\beta \cdot \bar{X}_\beta - \bar{X}|, \quad (11)$$

$$\bar{D}_\delta = |\bar{C}_\delta \cdot \bar{X}_\delta - \bar{X}|$$

$$\bar{X}_1 = \bar{X}_\alpha - \bar{A}_\alpha \cdot (\bar{D}_\alpha), \quad \bar{X}_2 = \bar{X}_\beta - \bar{A}_\beta \cdot (\bar{D}_\beta), \quad (12)$$

$$\bar{X}_3 = \bar{X}_\delta - \bar{A}_\delta \cdot (\bar{D}_\delta)$$

$$\bar{X}(t+1) = \frac{\bar{X}_1 + \bar{X}_2 + \bar{X}_3}{3} \quad (13)$$

4) 攻击猎物

狩猎完成的标志是猎物停止移动, 这一过程可以通过降低 \bar{a} 来实现。当随机值 \bar{A} 在[-1, 1]时, 搜索代理的下一个位置可以在当前位置与猎物位置之间的任何位置进行更新。算法中, 当 $|\bar{A}| < 1$ 表示强制狼攻击猎物。

5) 寻找猎物

灰狼常常分头搜索猎物, 同时根据 α 、 β 和 δ 的位置来攻击猎物, 当 $|\bar{A}| > 1$ 时, 灰狼被迫离开猎物, $|\bar{A}| < 1$ 时灰狼强制狼攻击猎物, 直到满足条件时, GWO 算法被终止。

1.3 支持向量回归算法原理

支持向量机(Support Vector Machine, SVM)是由 Vapnik^[20]等人在统计学习理论上提出的一种新型分类器。SVM 的主要思想是通过使用非线性映射算法将低维输入空间线性不可分的样本转化到高维特征空间使其线性可分。近年来, 支持向量机被应用于回归、预测方面, 从而衍生出支持向量回归机(Support Vector Regression, SVR)。

支持向量回归机作为回归模拟, 与支持向量机

一样保留了结构风险最小化的特点。对于非线性问题, 同样采用核函数来解决, 将目标问题化解为最优二次规划问题。SVR 的关键是寻找拟合函数 $f(x) = \mathbf{w}^* \varphi(x) + b$, SVR 的原理简述如下^[21]。

假设一组训练样本 $(\mathbf{x}_i, \mathbf{y}_i) \in R^n \times R, i=1, \dots, l$, 其中, \mathbf{x}_i 是输入向量, \mathbf{y}_i 是输出向量, l 是样本量。

SVR 的特征函数为

$$f(x) = \mathbf{w}^* \varphi(x) + b \quad (14)$$

式中: $\varphi(\cdot): R^n \rightarrow R^{n_h}$ 是从原始空间到核空间的映射函数; \mathbf{w} 是权重矩阵; b 是偏差。

支持向量回归机需要引入 ε -不敏感损失函数和松弛因子($\xi_i, \xi_i^* \geq 0$), 才能达到在高维空间上线性可分, 同时保证经验风险最小, 故引入损失函数和松弛因子后的优化目标函数和约束条件如下:

$$\min \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (15)$$

$$\text{s.t.} \begin{cases} \mathbf{y}_i - \mathbf{w}^T \mathbf{x}_i - b \leq \varepsilon + \xi_i \\ \mathbf{w}^T \mathbf{x}_i + b - \mathbf{y}_i \leq \varepsilon + \xi_i^* \quad (i=1, \dots, l) \\ \xi_i, \xi_i^* \geq 0 \end{cases} \quad (16)$$

式中, C 被称为惩罚参数, 用于平衡拟合的精度与算法的复杂程度。

对于非线性回归问题, 采用核函数将非线性输入样本映射到高维空间拟合后得到决策函数:

$$f(x) = \sum_i^l (\alpha_i - \hat{\alpha}_i) k(x_i, x) + b \quad (17)$$

本文采用的核函数为

$$k(x_i, x) = \exp \left\{ \frac{-\|x - x_i\|}{2\sigma^2} \right\} \quad (18)$$

1.4 CEEMD-SVR-GWO 预测模型

本小节介绍 CEEMD-SVR-GWO 模型。首先, 采用 CEEMD 方法处理原始风速时间序列, 得到从高频到低频包含原始数据不同特征的 IMF_s 和残余分量 Residual。其次, 利用 GWO 优化 SVR 模型对各个分量进行预测。最后, 将所有预测结果与 GWO 优化 SVR 模型再次集成, 作为最终的预测结果。图 2 是 CEEMD-SVR-GWO 模型的基本结构。

2 实证研究

2.1 数据准备

从气象部门获取重庆市某监测点 2016 年 2 月 1 日—2016 年 2 月 29 日的按小时级采集的时序风速数据, 共 696 个, 其中缺失值为 2016/2/5/3:00 和 2016/2/15/21:00 两个数据, 在文中, 用前一小时数据与后一小时数据的平均值代替缺失值。

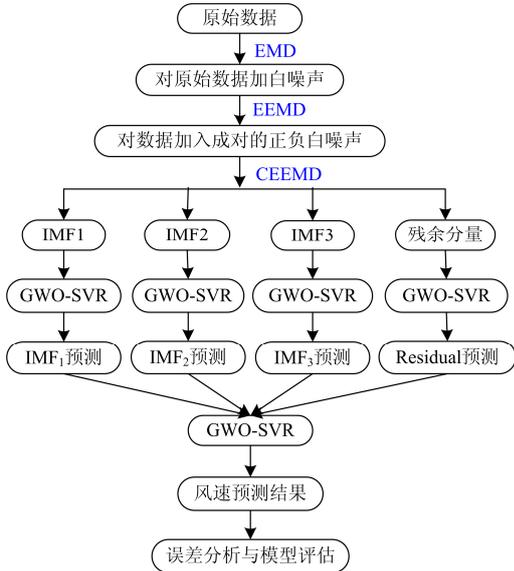


图2 模型的基本结构

Fig. 2 Basic structure of the model

样本数据分为两组：训练集和测试集。前 648 个数据作为模型训练集，后 48 个数据作为模型测试集。考虑一般性，采用迭代式预测模式，用前 3 个点预测下一个点的模式来进行整体预测。首先，对风速的原始信号进行 CEEMD 分解，将其分解为 IMF₁、IMF₂、IMF₃、IMF₄ 和残余分量 Residual。图 3 所示为原始信号的分解图。

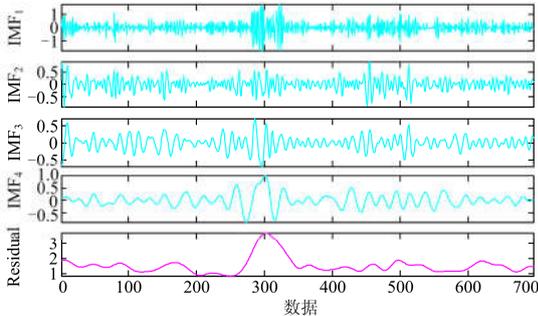


图3 原始信号分解图

Fig. 3 Decomposition of the original signal

2.2 评估标准

为对误差进行具体量化评价，本文采用实际值与预测值的平均相对误差(MAPE)、均方误差(MSE)、平均绝对误差(MAE)及平均误差(ME)四个指标来衡量预测精度，值越小，则模型越优。四个指标的定义如式(19)一式(22)。

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

$$MSE = \frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i)^2 \quad (20)$$

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

$$ME = \frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i) \quad (22)$$

式中：N 代表测试样本数；y_i 和 \hat{y}_i 分别代表第 i 时刻的实际值和预测值。

2.3 模型比较

为了验证所提出的模型在预测精度上的优越性，引入了一些基准预测模型作对比。因此，提出了单智能预测模型(SVR-GWO)，不同分解方法的集合模型(EMD-SVR-GWO、EEMD-SVR-GWO、CEEMD-SVR-GWO)，还有具有相同分解集合方法的不同优化算法模型(CEEMD-SVR-GWO、CEEMD-SVR-CS、CEEMD-SVR-ABC、CEEMD-SVR-WOA)。在这些模型中，都运用了以 RBF 为核函数的 SVR，并且用不同的优化算法来优化 SVR 的参数。换句话说，本文建立了六个基准模型与新提出的模型 CEEMD-SVR-GWO 进行比较。如图 4 是所有模型的预测图，其中图 4(a)是 SVR-GWO、EMD-SVR-GWO、EEMD-SVR-GWO、CEEMD-SVR-GWO 与原始序列实测值的拟合图；图 4(b)是 CEEMD-SVR-GWO、CEEMD-SVR-CS、CEEMD-SVR-ABC、CEEMD-SVR-WOA 与原始序列实测值的拟合图。图 5 是所有模型的预测误差图。表 1 是所有方法的误差对比结果。

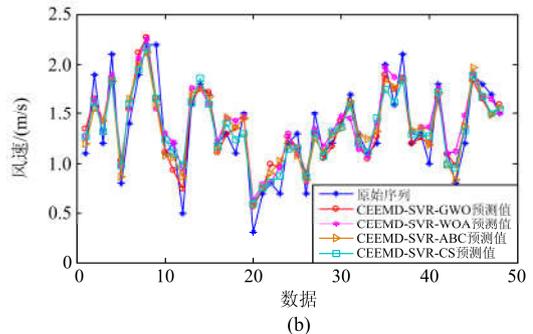
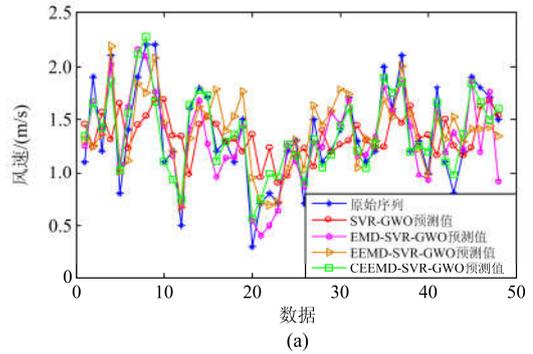


图4 所有模型预测图

Fig. 4 Predictions of all models

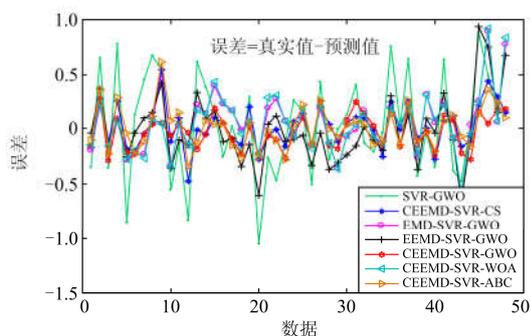


图 5 所有模型预测误差图

Fig. 5 Prediction error of all models

表 1 模型误差分析

Table 1 Model error analysis

模型	MAPE	MSE	MAE	ME
SVR-GWO	36.32%	0.211 5	0.379 1	-2.772 6
EMD-SVR-GWO	17.66%	0.076 5	0.210 2	-1.868 0
EEMD-SVR-GWO	23.14%	0.104 2	0.255 8	1.561 6
CEEMD-SVR-GWO	13.56%	0.036 2	0.151 9	0.206 3
CEEMD-SVR-CS	14.38%	0.041 2	0.159 0	0.225 0
CEEMD-SVR-ABC	13.91%	0.039 1	0.155 6	0.216 6
CEEMD-SVR-WOA	16.09%	0.046 5	0.173 7	1.846 3

从图 4、图 5 以及表 1 可以得出以下结论:

1) 无论哪种分解集合模型, 包括 EMD、EEMD 和 CEEMD 方法(EMD-SVR-GWO、EEMD-SVR-GWO、CEEMD-SVR-GWO)都要比单智能模型(SVR-GWO)的预测精度高。这一结果充分证明了分解与集合的思想可以有效地提高模型的表现能力, 并充分挖掘数据的内在属性。

2) 对于分解方法, 很明显 CEEMD 方法(CEEMD-SVR-GWO)预测效果比 EMD 和 EEMD 方法(EMD-SVR-GWO、EEMD-SVR-GWO)要好, 这三种分解方法对应的 MAPE 值分别为 17.66%、23.14%、13.56%。这个表现在 CEEMD 既克服了 EMD 模态混叠的问题, 也解决了由 EEMD 产生的残留噪声问题。

3) 对于优化算法, 可以得出结论: GWO 优化算法(CEEMD-SVR-GWO)比 CS 优化算法、ABC 优化算法和 WOA 优化算法的对应方法(CEEMD-SVR-CS、CEEMD-SVR-ABC、CEEMD-SVR-WOA)精度高。这是因为 GWO 优化算法可以更好地保持探索和局部寻优之间的平衡。避免局部最优解与快速收敛的问题。这四种方法对应的 MAPE 值分别为 13.56%、14.38%、13.91%、16.09%。

4) 由图 5 所示的所有模型预测误差图可以看出, CEEMD-SVR-GWO 模型拟合的误差最小, 与

其余几个模型相比, 误差曲线波动较小。这也证明了我们前面得出的结论: 该模型的预测精度相对较高。反而 SVR-GWO 模型的波动最大, 由此也可以得出结论, 结合分解集合方法的模型表现较好, 可以挖掘数据潜在的内部特征。

3 结论

本文提出了一种基于互补型集成经验模态分解和灰狼优化算法优化支持向量回归机参数的预测模型并用于超短期风速预测。该模型分为三个步骤: 首先对非平稳的风速时间序列进行 CEEMD 分解, 分解为一系列的相对平稳分量; 然后, 用 SVR 对各个分量进行预测, 针对各个分量的特点利用 GWO 算法优化 SVR 的参数; 最后, 将所有预测的分量结果整合作为最终结果。在实验中, 提出的 CEEMD-SVR-GWO 模型被用于重庆超短期风速预测, 该模型与其他基准模型相比具有一定的优越性。实验证明, 运用 CEEMD 方法处理一些高波动、不规则的序列可以获得相对平稳的分量, 再利用人工智能方法进行预测, 可以较大地提高预测精度, 从而得到满意的结果。

参考文献

- [1] 叶林, 杨丹萍, 赵永宁. 风电场风能资源评估的测量-关联-预测方法综述[J]. 电力系统自动化, 2016, 40(3): 140-151.
YE Lin, YANG Danping, ZHAO Yongning. Overview of wind resource measure-correlate-predict methods for wind farms[J]. Automation of Electric Power Systems, 2016, 40(3): 140-151.
- [2] 吴兴华, 周晖, 黄梅. 基于模式识别的风电场风速和发电功率预测[J]. 继电器, 2008, 36(1): 27-32.
WU Xinghua, ZHOU Hui, HUANG Mei. Wind speed and generated power forecasting based on pattern recognition in wind farm[J]. Relay, 2008, 36(1): 27-32.
- [3] 钱政, 裴岩, 曹利霄, 等. 风电功率预测方法综述[J]. 高电压技术, 2016, 42(4): 1047-1060.
QIAN Zheng, PEI Yan, CAO Lixiao, et al. Review of wind power forecasting method[J]. High Voltage Engineering, 2016, 42(4): 1047-1060.
- [4] 薛禹胜, 郁琛, 赵俊华, 等. 关于短期及超短期风电功率预测的评述[J]. 电力系统自动化, 2015, 39(6): 141-151.
XUE Yusheng, YU Chen, ZHAO Junhua, et al. A review on short-term and Ultra-short-term wind power prediction[J]. Automation of Electric Power Systems, 2015, 39(6): 141-151.

[5] LYDIA M, SURESH K S, IMMANUEL S A, et al. Linear and non-linear autoregressive models for short-term wind speed forecasting[J]. Energy Conversion and Management, 2016, 112: 115-124.

[6] 修春波, 任晓, 李艳晴, 等. 基于卡尔曼滤波的风速序列短期预测方法[J]. 电工技术学报, 2014, 29(2): 253-259.
XIU Chunbo, REN Xiao, LI Yanqing, et al. Short-term prediction method of wind speed series based on Kalman filtering fusion[J]. Transactions of China Electrotechnical Society, 2014, 29(2): 253-259.

[7] LI Zhi, YE Lin, ZHAO Yongning. Short-term wind power prediction based on extreme learning machine with error correction[J]. Protection and Control of Modern Power Systems, 2016, 1(1): 9-16. DOI: 10.1186/s41601-016-0016-y.

[8] MOHANDES M A, HALAWANI T O, REHMAN S, et al. Support vector machine for wind speed prediction[J]. Renewable Energy, 2004, 29(6): 939-947.

[9] 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): 1-8.
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): 1-8.

[10] 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.

[11] SHAO Haijian, WEI Haikun, DENG Xing, et al. Short-term wind speed forecasting using wavelet transformation and Ada boosting neural networks in Yunnan wind farm[J]. IET Renewable Power Generation, 2017, 11(4): 374-381.

[12] 吴忠强, 贾文静, 吴昌韩, 等. 基于 PSO-BSNN 的短期风速预测[J]. 电力系统保护与控制, 2015, 43(15): 36-41.
WU Zhongqiang, JIA Wenjing, WU Changhan, et al. Short-term wind speed forecasting based on PSO-BSNN[J]. Power System Protection and Control, 2015, 43(15): 36-41.

[13] 颜晓娟, 龚仁喜, 张千锋. 优化遗传算法寻优的 SVM 在短期风速预测中的应用[J]. 电力系统保护与控制, 2016, 44(9): 38-42.
YAN Xiaojuan, GONG Renxi, ZHANG Qianfeng. Application of optimization SVM based on improved genetic algorithm in short-time wind speed prediction[J]. Power System Protection and Control, 2016, 44(9): 38-42.

[14] 方必武, 刘涤尘, 王波, 等. 基于小波变换和改进萤火虫算法优化 LSSVM 的短期风速预测[J]. 电力系统保护与控制, 2016, 44(8): 37-43.
FANG Biwu, LIU Dichen, WANG Bo, et al. Short-term wind speed forecasting based on WD-CFA-LSSVM model[J]. Power System Protection and Control, 2016, 44(8): 37-43.

[15] HUANG N E, SHEN Z, LONG S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[J]. Proceedings of the Royal Society of London Series A, 1998, 454(1971): 903-995.

[16] WU Z H, HUANG N E. Ensemble empirical mode decomposition: a noise-assisted data analysis method[J]. Advances in Adaptive Data Analysis, 2009, 1(1): 1-41.

[17] 张淑英, 曹咏弘. EEMD 在惯性导航动态测试中的去噪应用[J]. 测试技术学报, 2013, 27(5): 419-424.
ZHANG Shuying, CAO Yonghong. EEMD denoising application in the dynamic test of the inertial navigation[J]. Journal of Test and Measurement Technology, 2013, 27(5): 419-424.

[18] YE H J, SHIEH J S, HUANG N E. Complementary ensemble empirical mode decomposition: a novel noise enhanced data analysis method[J]. Advances in Adaptive Data Analysis, 2010, 2(2): 135-156.

[19] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer[J]. Advances in Engineering Software, 2014, 69: 46-61.

[20] CORTES C, VAPNIK V. Support vector networks[J]. Machine Learning, 1995, 20(3): 273-297.

[21] AWAD M, KHANNA R. Support vector regression[J]. Neural Information Processing Letters & Reviews, 2007, 11(10): 203-224.

收稿日期: 2017-04-22; 修回日期: 2017-06-13

作者简介:

王静(1992—), 女, 硕士研究生, 主要研究方向为数据分析与建模; E-mail: 448457173@qq.com

李维德(1967—), 男, 通信作者, 博士, 教授, 主要从事数据分析与建模方面的研究。E-mail: weideli@lzu.edu.cn

(编辑 魏小丽)