

doi:10.3969/j.issn.1673-9833.2018.03.011

# 基于经验模态分解的 PSO-SVM 风电功率短期预测

田淑慧, 于惠钧, 赵巧红, 李 林

(湖南工业大学 电气与信息工程学院, 湖南 株洲 412007)

**摘 要:** 针对风电功率预测对精确度的要求, 结合风电机组功率特性曲线及支持向量机非线性拟合, 提出了一种基于经验模态分解(EMD)的粒子群算法(PSO)优化支持向量机(SVM)功率短期预测模型。即将 EMD 分解后的各个风速序列分量通过 PSO-SVM 模型预测, 将得到的各分量预测结果叠加后得到风速预测值, 将该值输入功率转化曲线, 即可得到最终的风电功率预测结果, 以实现风电机组功率的预测。通过对某地区风电场实际风速为例进行的仿真误差对比分析, 得知该组合预测模型不仅有效可行, 且有效提高了短期风电功率的预测精度。

**关键词:** 功率预测; 经验模态分解; 参数寻优; 支持向量机

中图分类号: TM614

文献标志码: A

文章编号: 1673-9833(2018)03-0059-06

## Short-Term Prediction of PSO-SVM Wind Power Based on Empirical Mode Decomposition

TIAN Shuhui, YU Huijun, ZHAO Qiaohong, LI Lin

(College of Electrical and Information Engineering, Hunan University of Technology, Zhuzhou Hunan 412007, China)

**Abstract:** In view of the accuracy requirement of wind power prediction, combined with the power characteristic curves of wind turbines and the nonlinear fitting of support vector machines, a particle swarm optimization (PSO) algorithm based on empirical mode decomposition (EMD) has thus been proposed to optimize the short-term prediction model of support vector machine (SVM) power. Based on the prediction of each wind speed sequence component after EMD decomposition by PSO-SVM model, the predicted values of each component will be superimposed, thus obtaining the predicted value of the wind speed. With the value input into the power conversion curve, the result of the final wind power prediction can be worked out, and the prediction of the power of wind turbines can be realized. A comparative analysis of the simulation error of the actual wind speed in a certain area verifies the effectiveness and feasibility of the combined forecasting mode, which effectively improves the prediction accuracy of the short-term wind power.

**Keywords:** wind power prediction; empirical mode decomposition; parameter optimization; support vector machine

## 0 引言

已有的风电机组功率预测方法可以分为如下两

种: 一是利用风电机组的功率特性曲线, 将原始的风速序列转化为风电功率的原始序列, 再对这些序列进

收稿日期: 2017-06-29

作者简介: 田淑慧(1990-), 女, 河南周口人, 湖南工业大学硕士生, 主要研究方向为风电机组最优功率控制,  
E-mail: 767130592@qq.com

通信作者: 于惠钧(1975-), 男, 河南驻马店人, 湖南工业大学教授, 主要从事系统保护与自动化技术方面的教学与研究,  
E-mail: 463298180@qq.com

行建模仿真, 以实现风电机组功率的预测; 二是将通过模型预测得到的风速预测数据, 直接通过风电机组功率特性曲线进行转换, 从而实现风电机组功率的预测<sup>[1]</sup>。由于风速所具有的规律性比风电场发电功率的规律性强, 为了得到较高的预测精度, 大多选择先对风电场风速进行预测的方法实现风电机组功率的预测。

经验模态分解是一个完全自适应的过程, 在信号分解前无需预设基函数, 这个特点使其与需建立先验性假设的谐波基函数的傅立叶分解方法和以小波基函数为前提的小波分解方法有着本质差别。经验模态分解根据数据所特有的时间尺度特征进行分解, 以实现局部平稳化, 对于风速的非线性及非平稳性特点较为适用。故本文提出一种基于经验模态分解(ensemble empirical mode decomposition, EMD)的粒子群算法(particle swarm optimization, PSO)优化支持向量机(support vector machine, SVM)功率的短期预测模型。首先, 对原始风速序列进行经验模态分解, 以获得一系列相对平稳且具有不同特点的序列分量, 以减少不同特征信息间的相互影响<sup>[2]</sup>。然后, 对各分量建立SVM预测模型, 并针对SVM对参数选择的敏感性, 选择PSO对SVM的参数进行寻优, 得到最优的参数组合<sup>[3]</sup>。接下来, 对通过PSO-SVM预测模型得到的各分量预测结果进行叠加得到风速预测值, 实现对风速的预测。最后, 将预测得到的风速经功率曲线转化, 即可得到风电功率的预测值, 最终实现对风电功率的预测<sup>[4]</sup>。

## 1 PSO优化SVM原理

### 1.1 支持向量机原理

对于一组给定的训练样本集 $(x_i, y_i)$ , 其中 $x_i \in \mathbf{R}^n$ 为输入向量,  $y_i \in \mathbf{R}^n$ 为输出向量。支持向量机的回归理论是通过引入非线性映射 $\phi(x)$ , 实现样本空间从低维向高维的变换。对于非线性问题, 估计函数 $f(x)$ 转换为如下形式<sup>[5]</sup>:

$$f(x) = W \cdot \phi(x) + b, \quad (1)$$

式中:  $W$ 为权重系数;

$b$ 为偏置项。

引入松弛变量 $\xi_i, \xi_i^*$ , 且 $\xi_i, \xi_i^*$ 均大于0, 则该问题转化为对偶问题, 根据统计学理论, 求解其最优优化问题

$$\min_{w, b} \frac{1}{2} \|W\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*), \quad (2)$$

式中 $C$ 为惩罚因子。

当拉格朗日乘子对偶参数 $\alpha_i$ 和 $\alpha_i^*$ 被引入后, 这

个具有线性不等式约束的二次规划最优问题可以转化为如下问题<sup>[6]</sup>:

$$\max \left[ -\frac{1}{2} \sum_{i,j=1}^n (\alpha_i^* - \alpha_i)(\alpha_j^* - \alpha_j) K(x_i, x_j) + \sum_{i=1}^l \alpha_i^* (y_i - \varepsilon) - \sum_{i=1}^n \alpha_i (y_i - \varepsilon) \right].$$

式中:  $K(x_i, x_j)$ 为径向基核函数;

$\varepsilon$ 为敏感损失系数。

本研究选径向基核函数为SVM的核函数, 定义径向基核函数为

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

式中 $\sigma$ 为待确定的核参数。

由此可得支持向量机的回归函数为

$$f(x) = \sum_{i,j=1}^n (\alpha_i - \alpha_i^*) K(x_i, x_j) + b. \quad (3)$$

核函数中参数 $\sigma$ 的取值对SVM模型的预测精度影响较大<sup>[7]</sup>。可见, SVM中需要选择的参数有核参数 $\sigma$ 和惩罚因子 $C$ 。

### 1.2 粒子群优化算法

PSO算法初始化为一群随机粒子在 $D$ 维空间解上通过追随当前最优粒子搜索的最优值, 经过不停地迭代, 寻找全局最优解。PSO算法简单、容易实现, 且没有过多参数需要调整, 因而具有收敛速度较快、精度较高等优点。

在迭代过程中, 粒子通过追踪这两个极值更新自身速度和在下一轮迭代中的位置: 一个是粒子本身找到的最优解, 另一个是全局最优解。粒子的速度和位置根据下列公式进行更新:

$$v_{id} = \omega v_{id} + c_1 r_1 (p_{id} - x_{id}) + c_2 r_2 (p_{gd} - x_{id}), \quad (4)$$

$$x_{id} = x_{id} + v_{id}. \quad (5)$$

式(4)~(5)中:

$\omega$ 为惯性权重因子, 为防止粒子在搜寻过程中陷入局部最优,  $\omega$ 通常不是固定的常数;

$c_1$ 和 $c_2$ 为加速常数, 为使收敛速度和搜寻效果保持均衡, 通常是非负值;

$r_1$ 和 $r_2$ 是 $[0, 1]$ 之间的随机数;

$x_{id}$ 和 $v_{id}$ 分别表示在 $D$ 维空间中, 随机粒子 $i$ 的位置和速度;

$p_{id}$ 和 $p_{gd}$ 分别表示第 $i$ 个粒子搜索到的当前最优位置和种群的最优位置。

可以看出, 在粒子更新过程中, 粒子更新前的速度具有随机性, 在搜索空间的扩大过程中, 粒子不断进行新的搜索, 因此具有全局优化能力, 反映了

PSO 算法在寻优过程中的多样化特点。公式 (4) 中的  $p_{id}-x_{id}$  表示当前位置与最优位置之间的距离, 为粒子的自我寻优过程, 是粒子的自我认知与思考;  $p_{gd}-x_{id}$  表示当前位置与群体最优位置之间的距离, 为粒子相互之间对信息的共享。群体中的粒子在求解空间的运动过程中, 通过信息共享而产生从无序到有序的演化过程<sup>[8]</sup>。

### 1.3 PSO 优化 SVM

SVM 中的参数  $C$  和  $\sigma$  的选择对其预测精度的影响较大, 拟通过将粒子群算法与 SVM 结合, 对 SVM 的参数进行优化, 选出最佳参数组合。其参数优化的目标函数如下:

$$\min f(C, \sigma) = \sum_{i=1}^n \left( y_i - \hat{y}_i \right)^2, \quad (6)$$

$$\text{s.t.} \begin{cases} C \in [C_{\min}, C_{\max}], \\ \sigma \in [\sigma_{\min}, \sigma_{\max}] \end{cases}$$

式中  $y_i$  和  $\hat{y}_i$  分别为第  $i$  个样本输出值和模型预测值。

可见, SVM 的参数优化, 是通过找到一组参数 ( $C, \sigma$ ) 以使公式中的  $f(C, \sigma)$  值最小。参数寻优具体步骤如下:

1) 初始化 PSO 种群的规模、惯性因子、迭代次数、加速因子等参数, 并且设置 SVM 的参数初始值  $C$ 、 $\sigma$  和  $\varepsilon$ 。

2) 根据当前位置计算各个粒子的适应度值, 并根据适应度值的大小跟踪新粒子当前最优位置与种群最优位置。

3) 按公式 (4) 更新每个粒子的速度与位置, 产生新的种群  $X(t)$ 。

4) 计算新种群的适应度值, 并与历史适应度值比较, 若当前位置优于历史最优位置和种群最优位置, 则替换; 否则保持不变。

5) 若满足寻优条件, 则结束寻优操作; 否则令  $t=t+1$ , 转第二步。

6) 将全局最优结果映射为 SVM 的参数。

7) 结束。

## 2 经验模态分解

经验模态分解是一种能够将非线性、非平稳性的时间序列分解成平稳化分量的信号处理方法。EMD 是完全自适应的分解过程, 具有很好的完备性和正交性, 在其分解过程中会保留数据本身的特性, 也不需要提前设定基函数, 因而克服了分析人员主观经验的干扰<sup>[9]</sup>。

假设非平稳、非线性的风速信号由一系列简单的

互相独立的固有模态函数 (intrinsic mode function, IMF) 构成, 则原始风速序列中不同尺度的波动通过 EMD 方法被依次分解为具有相同尺度特征的序列分量, 分解后的不同分量被人为间隔, 除去了相互间的影响, 因而有更强的规律性<sup>[10]</sup>。原始风速  $s(t)$  的 EMD 分解方法具体如下:

1) 找出原始风速信号全部的极值点, 并用三次样条函数拟合成原始风速数据序列的上包络线  $e_+(t)$  和下包络线  $e_-(t)$ 。

2) 计算上、下包络线的均值  $m_1(t)$ ,

$$m_1(t) = \frac{e_+(t) + e_-(t)}{2},$$

$$s(t) - m_1(t) = h_1(t).$$

式中:  $h_1(t)$  是原始风速信号的首个 IMF 分量。

3) 由于信号本身波动模式的特点, 所以需要反复筛选, 重复  $k$  次, 直到其满足 IMF 分量序列的条件, 由此得到第一个最高频率的 IMF 分量  $c_1(t)$ ,  $c_1(t)$  即为原始风速的第一个 IMF 分量:

$$h_{1(k-1)}(t) - m_{1k}(t) = h_{1k}(t),$$

$$c_1(t) = h_{1k}(t),$$

$$r_1(t) = s(t) - c_1(t).$$

4) 将去掉高频部分  $c_1(t)$  后的风速信号  $r_1(t)$  作为原始风速序列, 重复步骤  $n$  次, 得到  $n$  个 IMF 分量, 即

$$\begin{cases} r_1(t) - c_2(t) = r_2(t); \\ \vdots \\ r_{n-1}(t) - c_n(t) = r_n(t). \end{cases}$$

当  $r_n(t)$  为单调函数或者常数时, 循环结束, 原始风速  $s(t)$  被分解为<sup>[11]</sup>

$$s(t) = \sum_{j=1}^n c_j(t) + r_n(t). \quad (7)$$

原始风速  $s(t)$  被分解为多个, 就有不同时间特征尺度的 IMF<sub>1</sub>、IMF<sub>2</sub>、…、IMF <sub>$n$</sub> , 即  $c_1(t)$ 、 $c_2(t)$ 、…、 $c_n(t)$  和余项  $r_n(t)$ 。相应地, 各个 IMF 分量包括了不同波动的频率段, 其由高到低依次不同且随信号的变化而变化。

## 3 基于 EMD-PSO-SVM 的功率预测模型

因为风速具有随机性、较强的非线性和非平稳性的特点, 一般的预测方法已经达不到风电机组功率预测对预测精度的要求。基于经验模态分解方法在处理非平稳序列信号的特殊性以及 PSO 算法对 SVM 参数优化的优越性<sup>[12]</sup>, 本文提出一种基于 EMD 和 PSO-SVM 的短期功率预测模型, 其流程如图 1 所示。

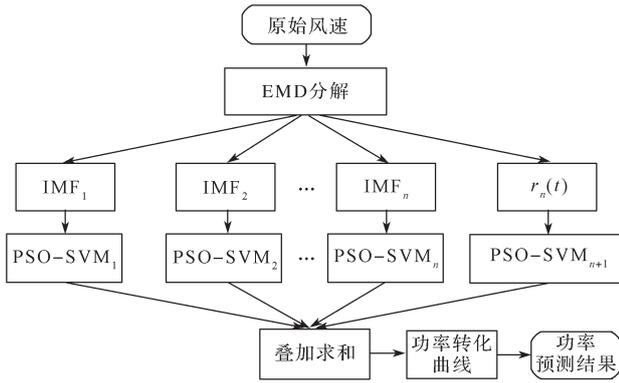


图1 预测模型流程图

Fig. 1 Flow chart of the prediction model

基于EMD和PSO-SVM功率预测流程描述如下:

1) 利用EMD, 将非线性、非平稳的原始风速序列分解成一系列相对平稳的IMF分量和残余分量序列之和, 即得到IMF各分量和余项 $r_n(t)$ 。

2) 分别对各IMF分量建立PSO-SVM预测模型, 基于SVM参数对其预测精确度的影响, 通过粒子群算法对SVM参数寻优, 得到优化后的参数组合。最后, 通过预测得到各分量序列的预测值。

3) 将通过PSO-SVM模型预测得到的各分量序列预测值进行叠加, 即可得到风速预测值。

4) 利用风电机组功率曲线, 实现风速预测值到风电功率预测值的转换。

5) 将EMD-PSO-SVM预测值分别与实际值和其他组合模型进行对比, 通过误差指标分析验证所提方法的精确性。

### 4 实例仿真与分析

以某地区风电场的实际风速为例, 进行仿真分析。所取的实验样本为每10 min采取1个点, 选取某风电机组正常运行时连续50 h的风速数据, 共计300个点。选取前200个采样点作为预测数据输入, 后100个采样点为预测数据。图2为风速原始数据。

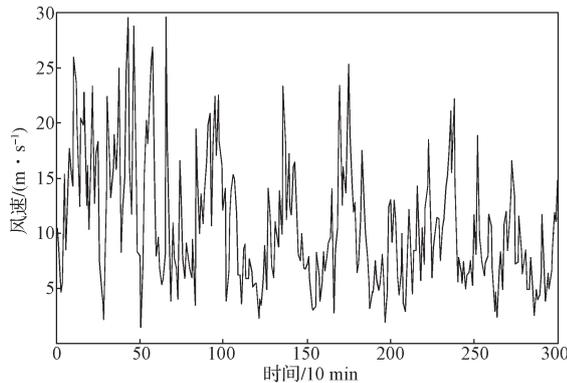


图2 原始风速序列

Fig. 2 Original wind speed sequence

由图2可知, 原始风速具有不同的波动尺度特征, 通过经验模态分解后, 原本非线性、非平稳性的原始风速序列被分解成5个时间序列分量 $IMF_1 \sim IMF_5$ 和一个最后的余项 $r_n(t)$ 。分解出来的分量波动程度从大到小, 具有不同的特征信息, 且各分量之间具有正交性, 实现了不同波动尺度分量的分离, 如图3所示。

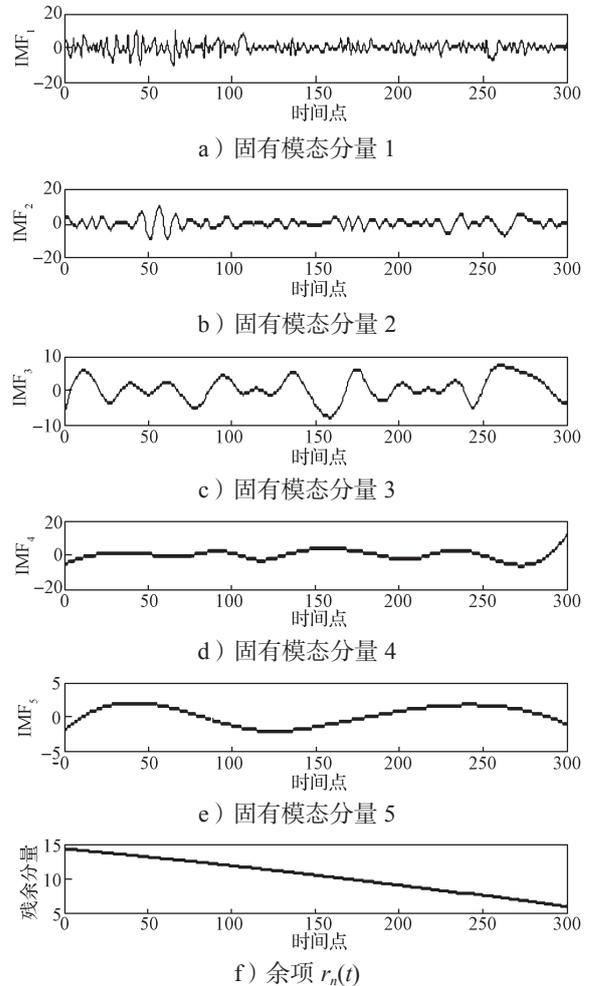


图3 原始风速EMD分解图

Fig. 3 EMD decomposition diagram of the original wind speed

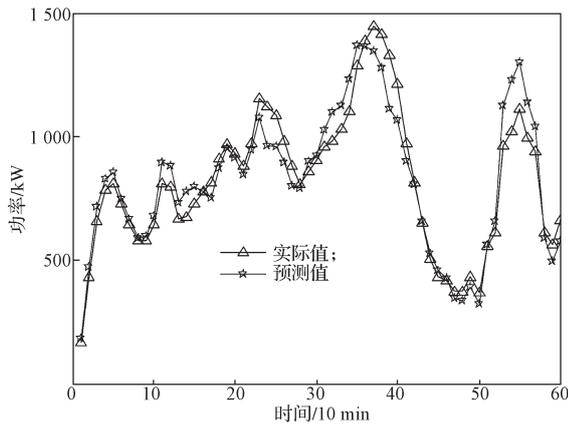
对每个IMF分量建立相应的PSO-SVM预测模型, 在PSO参数优化过程中, 得到SVM最优参数组合。将每个分量作为PSO-SVM输入特征, 可以降低分量预测模型的建模难度, 并减小分量之间的相互干扰。最后, 将各风速分量的预测值叠加输入功率曲线, 转换后即可得到相应的功率预测值。

风电功率预测的误差不可避免, 常用预测误差评价指标有衡量误差偏差大小的平均绝对百分比误差 (mean absolute percentage error, MAPE) 及衡量误差分布的均方根误差 (mean squared error, MSE) [13]。

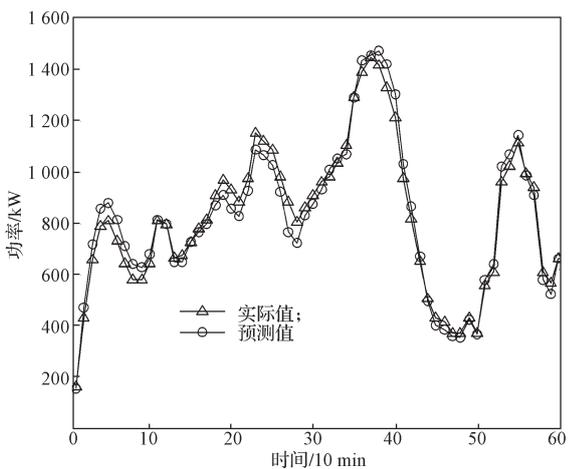
$$E_{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{L_i - \hat{L}_i}{L_i} \right| \times 100\%$$

$$E_{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n \left( \frac{L_i - \hat{L}_i}{L_i} \right)^2} \times 100\%$$

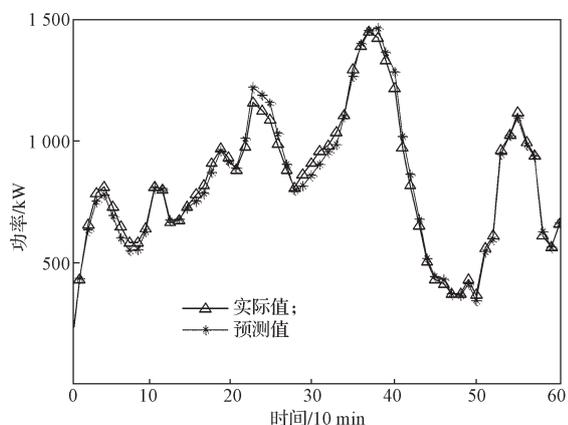
为了验证所提出的组合预测模型方法的有效性  
及精确度, 分别建立 SVM 模型、PSO-SVM 模型和  
EMD-PSO-SVM 模型, 将原始风速作为输入样本,  
对各个模型的预测结果分别与实测值进行比较, 如图  
4~5 所示。



a) SVM 模型



b) PSO-SVM 模型



c) EMD-PSO-SVM 模型

图 4 各模型的预测值与实测值对比

Fig. 4 Comparison between the predicted and measured values of different models

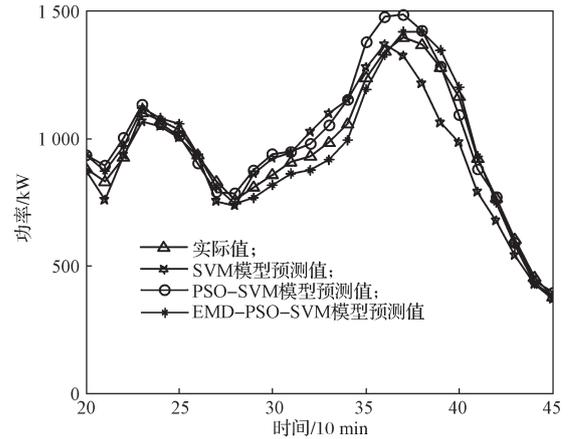


图 5 预测结果局部放大对比图

Fig. 5 Local magnification contrast diagram of prediction results

通过对比图 4 所示各模型的实际值与预测值曲线, 可以得知, 各模型的预测值与实际值均较为接近, 但相较而言, EMD-PSO-SVM 模型的预测曲线与实际值曲线的吻合度最高, 且 PSO-SVM 模型的预测值比 SVM 模型的预测值更接近于实际值。最后, 通过图 5 所示几种预测方法的放大对比图可以看出, EMD-PSO-SVM 的预测效果最好。

各模型的误差分析如表 1 所示。

表 1 各模型的主要误差指标值

Table 1 Main error indicators of different models

预测模型	$E_{MSE}/\%$	$E_{MAPE}/\%$
SVM	15.637	7.937 5
PSO-SVM	10.462	5.387 5
EMD-PSO-SVM	7.674	4.320 0

通过对比分析各模型的误差值可知, 组合模型 PSO-SVM 和 EMD-PSO-SVM 的预测精度均高于单一模型 SVM 的。PSO-SVM 预测模型的平均绝对百分比误差 (MAPE) 比单一模型减少了 2.55%, 这是因为通过粒子群算法, SVM 的参数被优化, 从而提高了预测模型的预测精度。EMD-PSO-SVM 预测模型的预测效果最好, 其平均绝对百分比误差 (MAPE) 比 PSO-SVM 预测模型的结果小 1.06%, 这是因为通过 EMD 分解后, 风速被平稳化处理, 减少了相互之间的影响。

## 5 结论

1) 可通过 EMD 方法, 将非平稳、非线性的风速序列分解成不同尺度的风速风量, 分解后的风速序列具有不同的特征信息, 且相对平稳。

2) 对分解出的不同频带平稳风速序列分别建立 PSO-SVM 预测模型, 并以粒子群算法对 SVM 的参数进行优化, 可使每个模型都得到合适参数, 进而降

低了风速的非平稳性对预测精度的影响。

3) 通过实例仿真, 验证了基于 EMD-PSO-SVM 的组合模型有效可行, 其有效提高了短期风电功率的预测精度。

#### 参考文献:

- [1] 王丽婕, 李 慧. 基于经验模态分解的风电功率短期预测方法 [J]. 北京信息科技大学学报, 2013, 28(6): 67-71.  
WANG Lijie, LI Hui. Short-Term Wind Power Forecast Based on Empirical Mode Decomposition[J]. Journal of Beijing Information Science and Technology University, 2013, 28(6): 67-71.
- [2] 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.  
YANG Deyou, CAI Guowei. The Short-Term Wind Speed Forecasting for Wind Farms Based on EEMD and LS\_SVM[J]. Journal of Northeast Dianli University, 2015, 35(3): 44-49.
- [3] 王 鹏. 基于支持向量机的风电功率预测和变桨距控制研究 [D]. 北京: 北京交通大学, 2012.  
WANG Peng. Wind Power Prediction and Pitch Control Based on Support Vector Machines[D]. Beijing: Beijing Jiaotong University, 2012.
- [4] PIERRO M, BUCCI F, DE FELICE M, et al. Multi-Model Ensemble for Day Ahead Prediction of Photovoltaic Power Generation[J]. Solar Energy, 2016, 134: 132-146.
- [5] 李胜刚. 基于支持向量机的短期风电功率预测 [D]. 株洲: 湖南工业大学, 2015.  
LI Shenggang. Short-Term Wind Power Forecasting Based on Support Vector Machine[D]. Zhuzhou: Hunan University of Technology, 2015.
- [6] 朱永强, 田 军. 最小二乘支持向量机在光伏功率预测中的应用 [J]. 电网技术, 2011, 35(7): 54-59.  
ZHU Yongqiang, TIAN Jun. Application of Least Squares Support Vector Machine in Photovoltaic Power Forecasting[J]. Power System Technology, 2011, 35(7): 54-59.
- [7] 黄晓松. 基于小波变换和支持向量机的短期风电功率预测 [D]. 天津: 河北工业大学, 2012.  
HUANG Xiaosong. Short-Term Wind Power Forecast Based on Wavelet Transform and Support Vector
- Machine[D]. Tianjin: Hebei University of Technology, 2012.
- [8] 秦 政, 包德梅, 赖晓路, 等. 风电场风功率预测系统研究 [J]. 计算机技术与发展, 2013, 23(7): 73-76.  
QIN Zheng, BAO Demei, LAI Xiaolu, et al. Research on Wind Power Forecast System for Wind Farms[J]. Computer Technology and Development, 2013, 23(7): 73-76.
- [9] 江岳春, 杨旭琼, 贺 飞, 等. 基于 EEMD-IGSA-LSSVM 的超短期风电功率预测 [J]. 湖南大学学报 (自然科学版), 2016, 43(10): 70-78.  
JIANG Yuechun, YANG Xuqiong, HE Fei, et al. Super-Short-Time Wind Power Forecasting Based on EEMD-IGSA-LSSVM[J]. Journal of Hunan University (Natural Sciences), 2016, 43(10): 70-78.
- [10] 江岳春, 杨旭琼, 陈礼锋, 等. 基于 EMD-SC 和 AGSA 优化支持向量机的超短期风电功率组合预测 [J]. 工程设计学报, 2017, 24(2): 187-195.  
JIANG Yuechun, YANG Xuqiong, CHEN Lifeng, et al. Super-Short-Time Wind Power Combination Forecasting Based on Support Vector Machine Optimized EMD-SC and AGSA[J]. Chinese Journal of Engineering Design, 2017, 24(2): 187-195.
- [11] 王 贺, 胡志坚, 张翌晖, 等. 基于聚类经验模态分解和最小二乘支持向量机的短期风速组合预测 [J]. 电工技术学报, 2014, 29(4): 237-245.  
WANG He, HU Zhijian, ZHANG Yihui, et al. A Hybrid Model for Short-Term Wind Speed Forecasting Based on Ensemble Empirical Mode Decomposition and Least Squares Support Vector Machines[J]. Transactions of China Electrotechnical Society, 2014, 29(4): 237-245.
- [12] OUYANG Tinghui, ZHA Xiaoming, QIN Liang. A Combined Multivariate Model for Wind Power Prediction [J]. Energy Conversion and Management, 2017, 144: 361-373.
- [13] 张立影, 孟令甲, 王泽忠. 基于双层 BP 神经网络的光伏电站输出功率预测 [J]. 电测与仪表, 2015, 52(11): 31-35.  
ZHANG Liying, MENG Lingjia, WANG Zezhong. Photovoltaic Power Station Output Power Prediction Based on the Double BP Neural Network[J]. Electrical Measurement and Instrumentation, 2015, 52(11): 31-35.

(责任编辑: 廖友媛)