

DOI: 10.19783/j.cnki.pspc.190449

# 基于 EMD-SA-SVR 的超短期风电功率预测研究

赵倩, 黄景涛

(河南科技大学电气工程学院, 河南 洛阳 471023)

**摘要:** 针对风电功率的高随机和强波动性, 提出一种基于 EMD-SA-SVR 的风电功率超短期预测方法。采用经验模态分解(Empirical Mode Decomposition, EMD)提取风电功率序列的不同特征。将原始序列分解为多个更具规律的模态, 针对每个模态序列建立各自的预测模型, 以消除不同特征之间的相互影响。鉴于支持向量回归(Support Vector Regression, SVR)好的泛化能力, 研究建立基于 SVR 的各模态预测模型。进一步采用模拟退火(Simulated Annealing, SA)算法对 SVR 参数进行优化以解决模型选择的多极值复杂非线性问题, 获得各模态分量的最优模型, 进而汇总各模态分量的结果得到风电功率预测值。在某风电场历史数据上的对比分析表明, EMD-SA-SVR 模型可以有效提高风电功率超短期预测精度。

**关键词:** 风电功率; 超短期预测; 经验模态分解; 支持向量回归; 模拟退火

## On ultra-short-term wind power prediction based on EMD-SA-SVR

ZHAO Qian, HUANG Jingtao

(College of Electrical Engineering, Henan University of Science and Technology, Luoyang 471023, China)

**Abstract:** An ultra-short-term wind power prediction method based on EMD-SA-SVR is proposed for the high randomness and strong fluctuation. Empirical Mode Decomposition (EMD) is used to extract different features lying in wind power sequence. By decomposing the original sequence into several more regular modes, the accurate prediction model can be built easily for each mode to eliminate the coupling between different features in the original sequence. The prediction models are constructed with Support Vector Regression (SVR) for its fine generalization performance. The Simulated Annealing (SA) algorithm is used to optimize the SVR parameters to solve the multi-extreme complex nonlinear problem of model selection, and the optimized model can be obtained for each mode. The wind power prediction value can be gained by summarizing the results of every single mode. The comparative analyses on a wind farm history data show that the EMD-SA-SVR model can effectively improve the accuracy of ultra-short-term wind power prediction.

This work is supported by National Natural Science Foundation of China (No. U1504617).

**Key words:** wind power; ultra-short-term prediction; empirical mode decomposition (EMD); support vector regression (SVR); simulated annealing (SA)

## 0 引言

由于风的间歇性以及随机性, 风电机组输出的功率曲线波动较大, 从而导致风电并网给电力系统调度带来严重的影响, 因此风电的准确预测是电网经济调度的首要依据<sup>[1]</sup>。国家电网有限公司规定超短期风电功率预测时间尺度为 4 h 内, 间隔 15 min<sup>[2]</sup>。超短期预测的目的是对风电机组进行控制, 便于电力系统实时调度, 解决电网调频问题。

风电预测主要方法包括时间序列法<sup>[3-4]</sup>、持续法<sup>[5]</sup>、BP 神经网络(BP Neural Network, BPNN)<sup>[6-7]</sup>、极限学习机<sup>[8-9]</sup>和 SVR<sup>[10-11]</sup>等。其中 SVR 具有非线性拟合能力强以及训练时间短等优点, 故在超短期风电功率预测研究中获得了较多的使用。文献[12]与文献[13]均指出模型参数对其回归特性较为重要。在 SVR 模型参数优化研究中, 随机搜索与网格搜索均需要在所给的参数搜索范围内将每组参数代入模型计算结果, 这些方法耗时较长, 搜索效率较低, 也有可能错失参数空间上的重要组合解。大量的智能搜索算法被学者们采用, 如遗传算法和粒子

基金项目: 国家自然科学基金项目资助(U1504617)

群(Particle Swarm Optimization, PSO)等<sup>[14-17]</sup>, 实验证明采用智能搜索算法对 SVR 模型参数优化可以改善超短期风电功率预测效果。

由于风的复杂特性, 简单的回归模型已经不能满足预测精度的需要<sup>[18]</sup>。因此, 需要对复杂多变的原始风电功率序列预先进行处理, 获得较规律的模态特征, 应用 EMD 分解方法针对非线性的时间序列进行处理效果有所改善<sup>[19-20]</sup>。文献[21]提出把无规律性的风速时间序列分解, 得到较有规律的分量序列, 预测性能得到有效提升。为进一步提高模型预测精度, 本文在对风电功率序列进行 EMD 分解的基础上, 对 SVR 参数进行优化研究, 鉴于 SA 算法收敛速度较快、寻优效果也较好<sup>[22]</sup>, 本文针对某风电场超短期功率预测问题, 根据监测数据, 提出一种基于 EMD-SA-SVR 的超短期风电功率预测方法。

## 1 经验模态分解原理

EMD 是 Huang 于 1998 年提出的一种信号处理方法<sup>[23]</sup>, 该方法适用于针对非平稳时间序列数据的分析, 使其分解为较简单的固有模态函数(Intrinsic Mode Function, IMF), 各个 IMF 均相互独立且有较强的规律性。该方法可以提高回归模型的预测精度。

从原始序列  $x(t)$  中分离出第一个 IMF 分量获得剩余分量, 将剩余分量作为新的时间序列, 重复采用 EMD 方法获得各个 IMF 子序列和 1 个残余序列, 最终结果表达式如下。

$$\begin{cases} x(t) - c_1(t) = r_1(t) \\ r_1(t) - c_2(t) = r_2(t) \\ r_2(t) - c_3(t) = r_3(t) \\ \vdots \\ r_{n-1}(t) - c_n(t) = res(t) \end{cases} \quad (1)$$

式中:  $c_n(t)$  为第  $n$  个 IMF 序列分量;  $r_{n-1}(t)$  为第  $n-1$  次采用 EMD 方法分解后的剩余分量;  $res(t)$  为最终的残余分量。

## 2 EMD-SA-SVR 风电功率预测建模方法

### 2.1 支持向量回归原理

SVR 是由 Vapnik<sup>[24]</sup>提出、以统计学理论为基础、基于 VC 维理论和结构风险最小化原理的一项数据挖掘技术。其基本思想是将影响因素作为输入变量  $(x_1, x_2, \dots, x_m)$ , 映射到一个高维的特征空间  $(\varphi(x_1), \varphi(x_2), \dots, \varphi(x_m))$ , 将非线性模型转化为一个高维特征空间中的线性回归模型。

$$f(x) = \omega^T \varphi(x) + b \quad (2)$$

式中,  $\omega$  和  $b$  是模型参数。

利用结构风险最小化原则, 得到表达式(3)的风险函数。

$$\min_{\omega, b} \frac{1}{2} \|\omega\|^2 + c \sum_{i=1}^m \ell(f(x_i), y_i) \quad (3)$$

式中:  $\ell$  为损失函数;  $\|\omega\|^2$  为结构风险。

求风险函数的最小值, 等价于求解表达式(4)的约束最小化优化问题。

$$\begin{aligned} \min L &= \frac{1}{2} \|\omega\|^2 + c \sum_{i=1}^m (\xi_i + \hat{\xi}_i) \\ \text{s.t.} &\begin{cases} y - (\omega, \varphi(x_i)) - b \leq \varepsilon + \xi_i \\ -y + (\omega, \varphi(x_i)) + b \leq \varepsilon + \hat{\xi}_i \\ \xi_i \geq 0, \hat{\xi}_i \geq 0, i = 1, 2, \dots, m \end{cases} \end{aligned} \quad (4)$$

式中:  $\xi_i$  和  $\hat{\xi}_i$  为松弛变量;  $c$  为惩罚系数, 并且  $c > 0$ ;  $\varepsilon$  为不敏感损失系数。

高维特征空间中内积运算可用核函数代替, 为方便计算, 引入拉格朗日函数将上述问题转化为对偶问题, 可得非线性函数为

$$f(x) = \sum_{i=1}^m (\alpha_i - \hat{\alpha}_i) K(x_i, x) + b \quad (5)$$

式中:  $\alpha_i$  和  $\hat{\alpha}_i$  为拉格朗日乘子;  $K(x_i, x)$  为核函数。

核函数是将低维非线性函数转化为高维的线性函数, 选择合适的核函数对于回归问题的解决起着关键的作用。本文选用径向基核函数, 其定义如式(6)所示。

$$K(x_i, x) = e^{-\frac{\|x_i - x\|^2}{g^2}} \quad (6)$$

式中,  $g$  为径向基核函数的宽度, 是 SVR 模型重要的参数。

由式(3)可知, 模型参数  $c$  越大, 其模型的训练精度越高, 但泛化能力变差, 反之误差就越大, 泛化能力随之增强。核函数宽度  $g$  决定了训练样本变换后的范围,  $g$  取值越大, 训练样本变换后的范围越大, 反之减小。综上, 合理选择模型参数  $(c, g)$  是使其模型发挥最优性能的关键。而盲目试凑需要耗费大量时间, 且往往不容易找到较优的结果。针对这一问题, 提出了采用 SA 方法对 SVR 模型中参数  $(c, g)$  进行寻优以达到更好的建模效果。

### 2.2 模拟退火原理

Metropolis 等人<sup>[25]</sup>依据金属退火原理于 1953 年提出 SA 算法, 金属状态  $S$  是否转变为新的状态是依据 Metropolis 准则, 该准则主要采用通过一定概率来确定是否接受新状态的采样法, 其中涉及到的

概率表达式如式(7)所示。

$$P = e^{\frac{-(E_j - E_i)}{kT}} \quad (7)$$

式中:  $E_i$  为当前状态  $i$  的能量;  $E_j$  为新状态  $j$  的能量;  $k$  为玻尔兹曼常数;  $T$  为金属温度。

新状态接受后需要更新金属温度, 更新规则如式(8)所示。

$$T^{t+1} = \lambda T^t \quad (8)$$

式中:  $T^{t+1}$  代表第  $t+1$  次迭代的温度;  $T^t$  代表第  $t$  次迭代的温度;  $\lambda$  为温度衰减系数, 且  $\lambda \in (0,1)$ 。

### 2.3 EMD-SA-SVR 建模流程

对原始风电功率数据依据 EMD 原理进行分解, 得到各个分量序列, 将每个分量根据 SA 原理并对 SVR 模型参数  $(c, g)$  优化, 构建 SA-SVR 模型, 各个模型的预测结果相加获得超短期风电功率预测结果, 建模过程如图 1 所示。

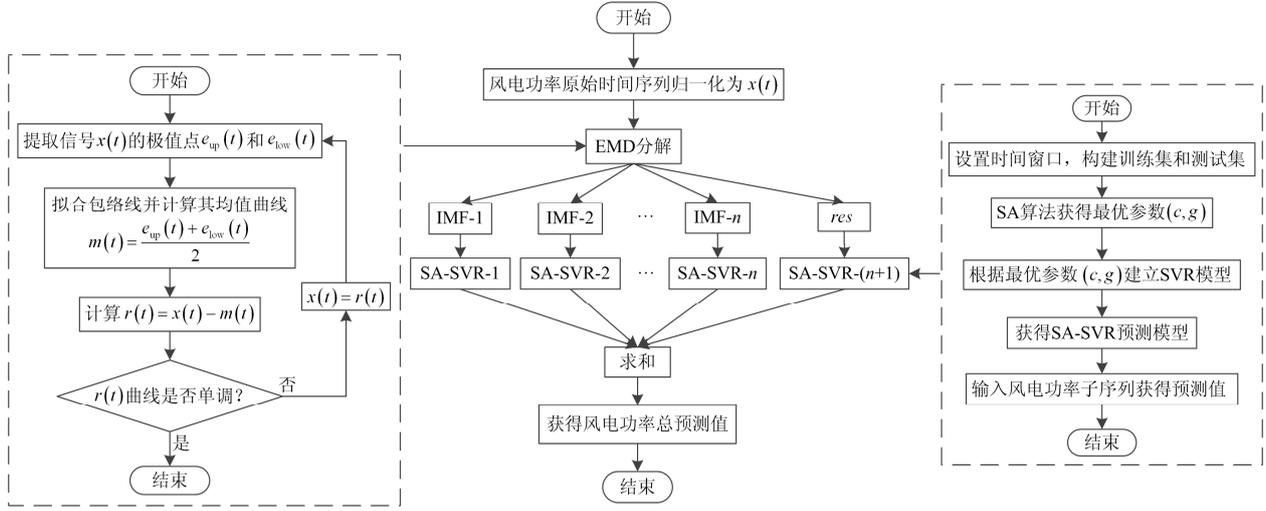


图 1 EMD-SA-SVR 预测流程  
Fig. 1 EMD-SA-SVR forecasting process

### 3 超短期风电功率预测及结果分析

以某风电场 2017 年 10 月以及 11 月实际运行数据为例进行建模分析, 数据采样间隔为 15 min。由图 2 时间序列变化曲线可知, 共 5 856 个数据样本, 其中最高发电功率为 11 466.246 MW, 最低发电功率为 5 966.228 MW, 平均发电功率为 8 030.647 MW, 功率波动较大。

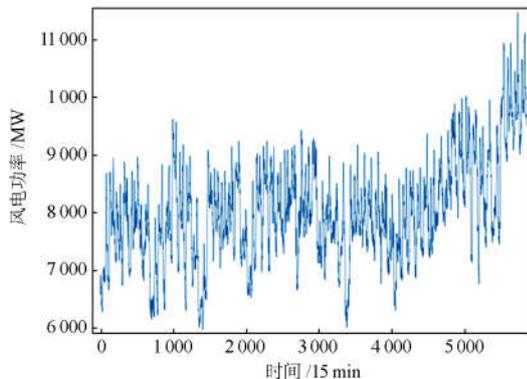


图 2 实际功率时间序列  
Fig. 2 Actual power time series

滚动建立 SVR 模型会使模型充分学习风力发电功率系统最新的变化规律, 因此选取时间窗口为 16(4 h)个时间点的数据, 例如用 1~16 点来预测第 17 点, 用 2~17 点来预测第 18 点。组成输入变量  $X$  与输出变量  $Y$  共计 5 840 组, 其中前 4 672 组样本用来构建训练集(总样本的 80%), 后 1 168 组样本用来构建测试集(总样本的 20%)。

为了避免求解中出现饱和现象, 实验前先对时间序列样本进行归一化处理, 使其样本值处于  $[0,1]$  之间, 归一化定义如式(9)。

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (9)$$

式中:  $x$  和  $x'$  分别为原始时间序列数据中归一化前后的功率值;  $x_{\max}$  和  $x_{\min}$  分别为历史数据中最大、最小功率。

模型的精确程度取决于误差指标, 取均方误差 (Mean Square Error, MSE)、平均绝对误差 (Mean Absolute Error, MAE) 和平方相关系数 (Squared correlation coefficient,  $R^2$ ) 作为判断模型预测效果的指标。

用  $MSE$  衡量模型计算值与真实值之间的偏差。其数值趋于零,反映了模型的预测误差小和精度高。即表达式为

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (10)$$

$MAE$  是所有单个观测值与算术平均值偏差的绝对值的平均,可以避免误差相互抵消的问题,并且能准确反映实际预测误差的大小,如式(11)所示。

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (11)$$

$R^2$  表示模型计算值与真实值之间的线性相关性,该指标的取值为(0,1),当其趋于1时表明模型对样本的计算值与真实值趋于一致,具体表达式如式(12)所示。

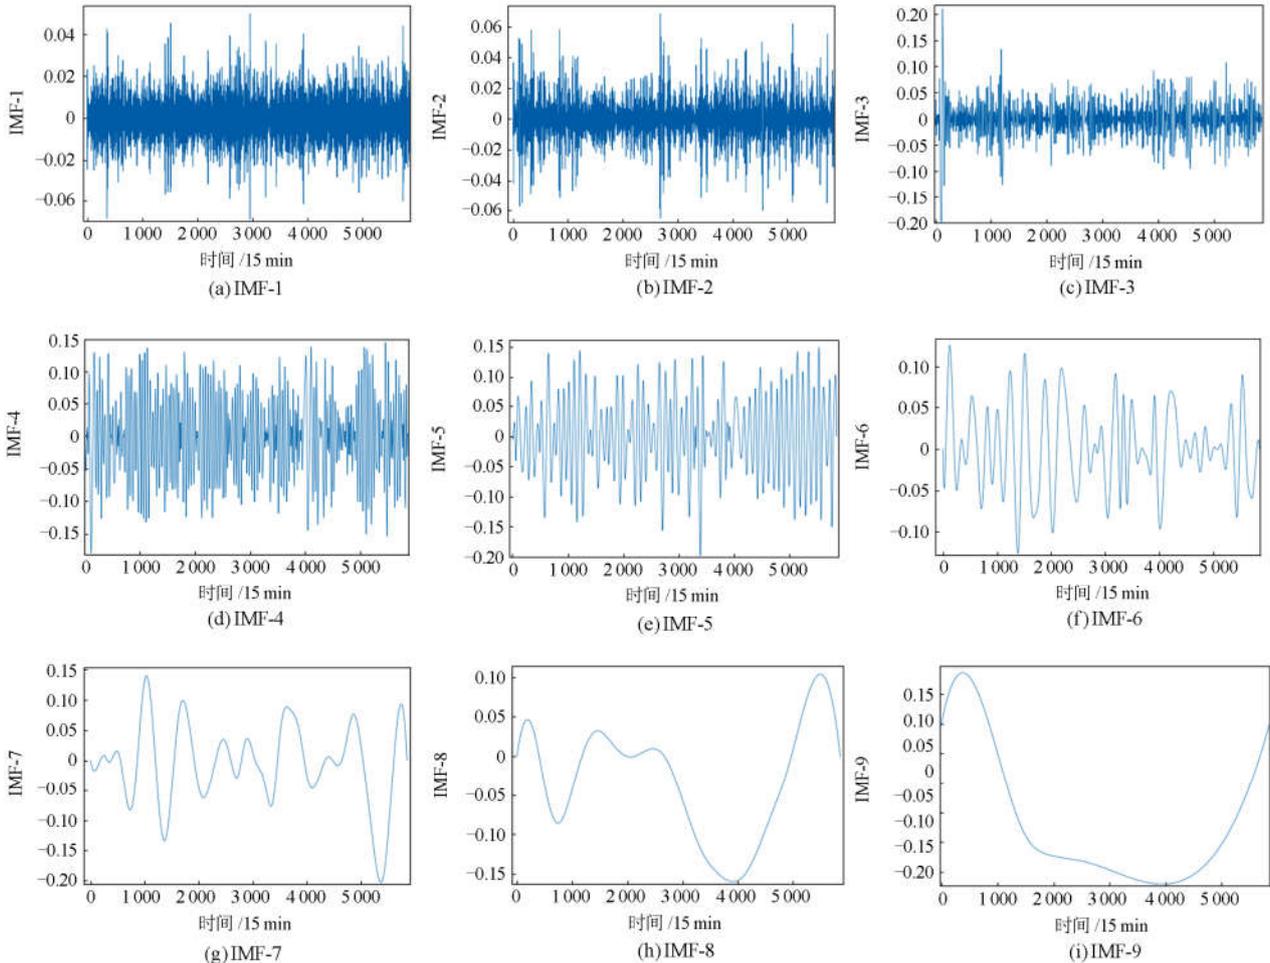
$$R^2 = \frac{\left( \sum_{i=1}^n (y_i - \bar{y})(\hat{y}_i - \bar{\hat{y}}) \right)^2}{\sum_{i=1}^n (y_i - \bar{y})^2 \sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}})^2} \quad (12)$$

式(10)—式(12)中:  $\hat{y}_i$  表示第  $i$  个样本的预测值;  $\bar{\hat{y}}$  表示预测样本的平均值;  $y_i$  表示第  $i$  个样本实际测量值;  $\bar{y}$  表示实际测量样本的平均值;  $n$  表示预测样本数。

根据 EMD-SA-SVR 流程图,采用 SA 对 SVR 模型参数 ( $c$ ,  $g$ ) 的搜索范围设为  $c \in (1, 10^4)$  和  $g \in (10^{-4}, 1)$ ,  $\varepsilon$  设为 0.000 1, 初始温度设为 2,  $\lambda$  设为 0.1, 迭代次数设为 100。

使用相同的实验数据样本,分别构建 EMD-SVR、EMD-PSO-SVR、SA-SVR 和 PSO-SVR 以及 SVR 和 BPNN 的预测模型。实验中涉及到算法的实现采用 Python 编程,在 PyCharm 环境下开发。实验计算机处理器为 Intel Core i3-6100, CPU 主频 3.7 GHz, 内存 4 GB, 操作系统为 Windows 10。

采用 EMD 方法对归一化后的风电功率时间序列进行分解,其各 IMF 序列和  $res(t)$  如图 3 所示,将图 2 中的非线性风电功率时间序列分解为 12 个具有不同特征的分量序列。



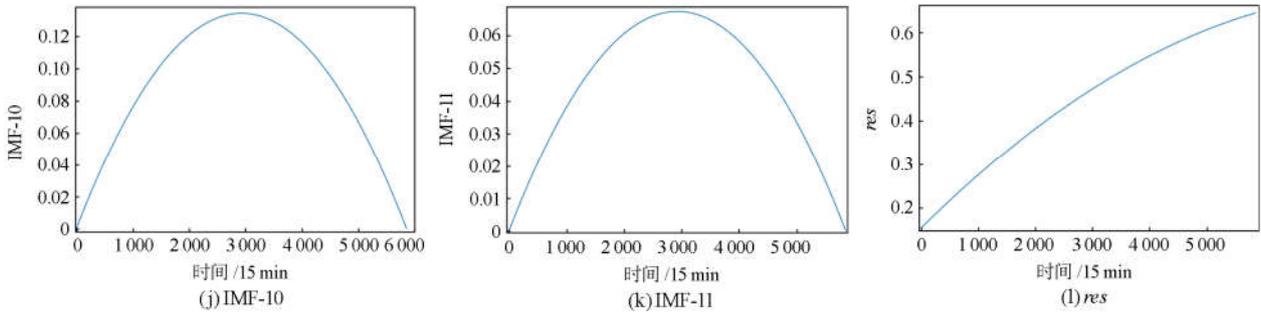


图 3 归一化后风电功率序列 EMD 分解结果

Fig. 3 Normalized wind power series EMD decomposition results

图 4 为 SVR 与 EMD-SA-SVR 模型在测试集上的预测效果。根据两模型的预测曲线，采用 EMD-SA-SVM 模型的回归效果较 SVR 模型好，预测误差小。虽然风速突变导致风电机组发出的功率随机性较强，但经过数据分解后再分别寻优建模预测可以更好地找出数据内在的趋势和规律。在实际功率时间曲线发生突变时，EMD-SA-SVM 模型能及时进行精确预测，使各个预测值与实际值更吻合。

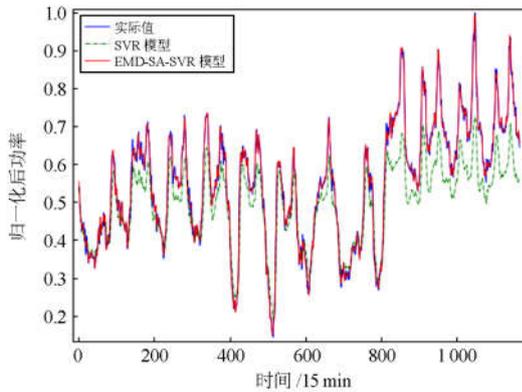
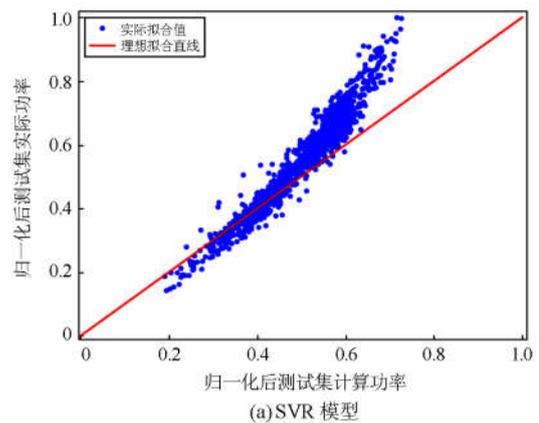


图 4 SVR 和 EMD-SA-SVR 模型测试结果

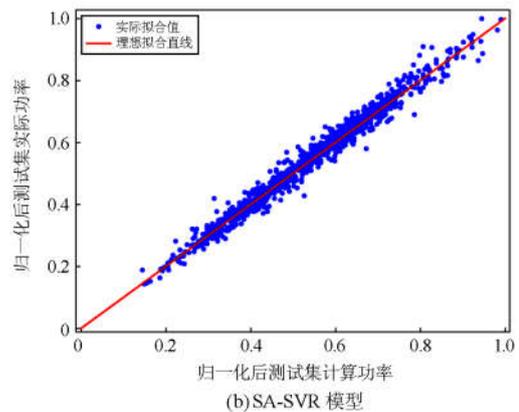
Fig. 4 SVR and EMD-SA-SVR model test results

图 5 分别为 SVR、SA-SVR、EMD-SVR 以及 EMD-SA-SVR 模型在测试集上的计算值与真实值。通过图 5(a)与图 5(b)、图 5(c)对比，显然采用 SA 优化或 EMD 分解均使模型预测趋势有所改善。根据图 5(d)可知同时采用 EMD 分解并对其进行 SA 寻优后的预测模型均比其余三种模型的回归特性好。

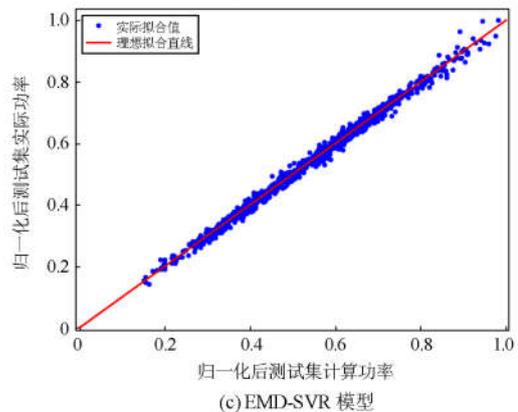
采用 SVR、SA-SVR 以及 EMD-SA-SVR 方法建立的模型，在测试集中计算值与真实值之差即绝对误差如图 6 所示。图中可以明显看出，EMD-SA-SVR 模型的绝对误差数值在零附近波动，与其余两种预测模型相比稳定性和预测精度均较高。



(a) SVR 模型



(b) SA-SVR 模型



(c) EMD-SVR 模型

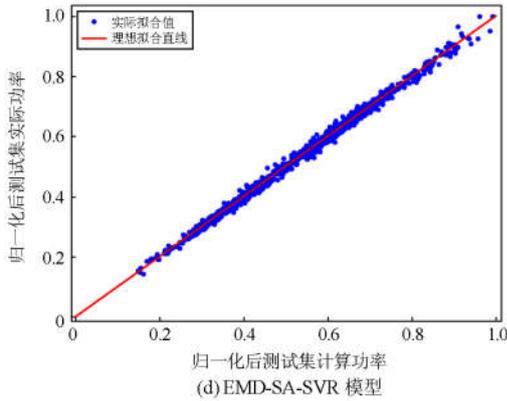


图 5 四种模型计算值与真实值

Fig. 5 Calculation and actual values of four models

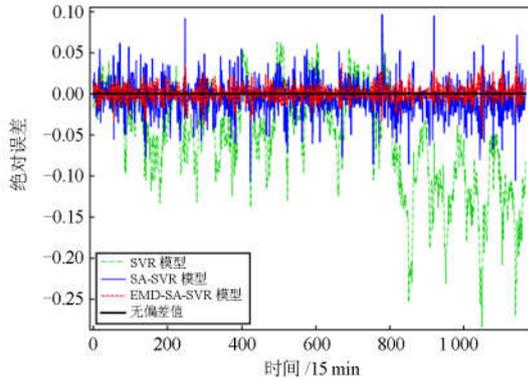


图 6 三种模型在测试集中的绝对误差

Fig. 6 Absolute error of three models in the test set

表 1 为不同模型的性能结果。通过各模型的训练时间  $t$  可知, 简单的 SVR 模型训练时间最短, 但根据  $MSE$  以及  $MAE$  两个测试集误差指标可以看出,

表 1 不同模型的性能对比分析

Table 1 Comparison of prediction results of different models

模型	$MSE(\times 10^{-4})$		$MAE(\times 10^{-3})$		$R^2$		$t/s$
	训练集	测试集	训练集	测试集	训练集	测试集	
BPNN	6.875	15.09	19.76	27.91	0.955 4	0.937 4	50.38
SVR	14.59	68.09	31.01	63.56	0.905 4	0.717 8	0.22
PSO-SVR	4.834	7.549	15.89	19.88	0.969 6	0.968 7	193.93
SA-SVR	4.603	5.149	15.67	16.74	0.970 1	0.978 6	15.93
EMD-SVR	1.467	1.507	9.051	9.281	0.990 5	0.993 8	15.78
EMD-PSO-SVR	1.146	1.342	8.074	8.821	0.992 6	0.994 4	964.66
EMD-SA-SVR	1.098	1.149	7.976	8.278	0.992 9	0.995 2	463.39

在实际风电场功率序列上的实验结果表明, 本文提出的 EMD-SA-SVR 方法预测精度明显提高, 泛化能力明显增强, 预测性能明显改善, 且优化过程耗时较短, 能够更好地进行超短期风电功率预测。

该模型与简单的 BPNN 模型在预测该问题时预测精度均较低, 与训练集误差指标对比表明, 两种简单的 SVR 和 BPNN 模型均出现严重的过拟合以及模型泛化能力差的情况, 难以满足要求。基于 PSO 和 SA 对各参数优化后, 模型性能较 SVR 均有明显改善, 经 SA 优化的结果优于 PSO 优化的结果, 同时 SA-SVR 训练时间远低于 PSO-SVR, 表明 SA-SVR 的预测精度以及搜索效率高于 PSO-SVR 模型, 说明 SA 在寻优过程中以一定的概率接受了错误解, 也避免了 PSO 算法易出现局部极值的缺点, 从而趋于全局最优解。

将风电功率序列进行经验模态分解后, 分别建立 EMD-SVR、EMD-PSO-SVR 以及 EMD-SA-SVR 预测模型。实验结果表明, 原始风电功率序列采用 EMD 分解能够获得比原始数据规律性更强的特征, 减少不同特征信息间的相互影响, 但同时模型训练时间均有所增加。在各 IMF 中进行 SA-SVR 建模, 对获得的单一 IMF 预测值进行相加可提升预测效果。在相同测试集中采用 EMD 分解方法的  $MSE$  和  $MAE$  数值均有明显的改善, 且与训练效果对比相差较小, 表明采用 EMD 分解方法可解决 SVR 模型预测精度低、模型过拟合以及泛化能力差的问题。采用 SA 方法优化参数后的模型主要性能指标  $MSE$ 、 $MAE$  有明显改善, 与 EMD-SVR 相比, 在训练集和测试集上均有所降低, 同时平方相关系数也更高。而采用 EMD-SA-SVR 模型的训练时间比经过 PSO 寻优的 EMD-PSO-SVR 模型明显缩短, 且模型在测试集上的表现更好。

#### 4 结论

本文基于风电功率历史数据建立了 EMD-SA-SVR 模型, 有效解决了超短期风电功率预测问题。采用的 EMD 方法可以有效提取原始风电功率序列

的不同特征, 使其具有强规律性的模态分量, 消除了不同特征之间的相互影响。建立了各模态的 SVR 回归模型, 并且针对每个模态分量序列采用模拟退火算法进行参数优化, 结果表明该方法具有全局优化能力, 可有效避免陷入局部极小值, 解决了 SVR 模型性能与参数之间存在的多极值复杂非线性问题, 所得模型泛化能力较好, 提高了 SVR 模型预测的准确性。与 BPNN、SVR、PSO-SVR、SA-SVR、EMD-SVR 和 EMD-PSO-SVR 算法的建模结果对比表明, 本文所提的 EMD-SA-SVR 方法具有更高的预测精度以及更强的泛化能力, 且优化耗时较 PSO 算法明显缩短, 对风电并网运行和优化调度具有一定指导意义。

### 参考文献

- [1] 乔颖, 鲁宗相, 闵勇, 等. 提高风电功率预测精度的方法[J]. 电网技术, 2017, 41(10): 3161-3169.  
QIAO Ying, LU Zongxiang, MIN Yong, et al. Research & application of raising wind power prediction accuracy[J]. Power System Technology, 2017, 41(10): 3161-3169.
- [2] 国家电网有限公司. 风电功率预测功能规范: Q/GDW 588—2011[S]. 北京: 中国电力出版社, 2011.  
State Grid Corporation of China. Function specification of wind power forecasting: Q/GDW 588—2011[S]. Beijing: China Electric Power Press, 2011.
- [3] 张立栋, 李继影, 吴颖, 等. 不同时间分辨率的风功率时间序列 ARIMA 模型预测[J]. 中国电力, 2016, 49(6): 176-180.  
ZHANG Lidong, LI Jiying, WU Ying, et al. ARIMA model forecast for wind power time series with different temporal resolutions[J]. Electric Power, 2016, 49(6): 176-180.
- [4] 陈昊, 张建忠, 许超, 等. 基于多重离群点平滑转换自回归模型的短期风电功率预测[J]. 电力系统保护与控制, 2019, 47(1): 73-79.  
CHEN Hao, ZHANG Jianzhong, XU Chao, et al. Short-term wind power forecast based on MOSTAR model[J]. Power System Protection and Control, 2019, 47(1): 73-79.
- [5] 穆钢, 杨修宇, 严干贵, 等. 基于风电场群汇聚演变趋势的场群持续功率特性预测方法[J]. 中国电机工程学报, 2018, 38(增刊): 32-38.  
MU Gang, YANG Xiuyu, YAN Gangui, et al. Prediction method of the durative characteristic for wind farm cluster based on cumulative evolution tendency[J]. Proceedings of the CSEE, 2018, 38(S): 32-38.
- [6] 范高峰, 王伟胜, 刘纯, 等. 给予人工神经网络的风电功率预测[J]. 中国电机工程学报, 2008, 28(34): 118-123.  
FAN Gaofeng, WANG Weisheng, LIU Chun, et al. Wind power prediction based on artificial neural network[J]. Proceedings of the CSEE, 2008, 28(34): 118-123.
- [7] CHITSAZ H, AMJADY N, ZAREIPOUR H. Wind power forecast using wavelet neural network trained by improved Clonal selection algorithm[J]. Energy Conversion and Management, 2015, 89: 588-598.
- [8] 李军, 李大超. 基于优化核极限学习机的风电功率时间序列预测[J]. 物理学报, 2016, 65(13): 130501-130501.  
LI Jun, LI Dachao. Wind power time series prediction using optimized kernel extreme learning machine method[J]. Acta Physica Sinica, 2016, 65(13): 130501-130501.
- [9] 王浩, 王艳, 纪志成. 基于改进极限学习机的风电功率预测仿真研究[J]. 系统仿真学报, 2018, 30(11): 4437-4447.  
WANG Hao, WANG Yan, JI Zhicheng. Simulation of wind power prediction based on improved ELM[J]. Journal of System Simulation, 2018, 30(11): 4437-4447.
- [10] ZENG Jianwu, QIAO Wei. Short-term wind power prediction using a wavelet support vector machine[J]. IEEE Transactions on Sustainable Energy, 2012, 3(2): 255-264.
- [11] ZAFIRAKIS D, TZANES G, KALDELLIS J K. Forecasting of wind power generation with the use of artificial neural networks and support vector regression models[J]. Energy Procedia, 2019, 159: 509-514.
- [12] FISCHER A, MONTUELLE L, MOUGEOT M, et al. Statistical learning for wind power: a modeling and stability study towards forecasting[J]. Wind Energy, 2017, 20(12): 2037-2047.
- [13] 琚垚, 祁林, 刘帅. 基于改进乌鸦算法和 ESN 神经网络的短期风电功率预测[J]. 电力系统保护与控制, 2019, 47(4): 58-64.  
JU Yao, QI Lin, LIU Shuai. Short-term wind power forecasting based on improved crow search algorithm and ESN neural network[J]. Power System Protection and Control, 2019, 47(4): 58-64.
- [14] YUAN Xiaohui, CHEN Chen, YUAN Yanbin, et al. Short-term wind power prediction based on LSSVM-GSA model[J]. Energy Conversion and Management, 2015, 101: 393-401.
- [15] 王贺, 胡志坚, 张翌晖, 等. 基于 IPSO-LSSVM 的风电功率短期预测研究[J]. 电力系统保护与控制, 2012, 40(24): 107-112.  
WANG He, HU Zhijian, ZHANG Yihui, et al. Short-term

- prediction of wind power based on IPSO-LSSVM[J]. Power System Protection and Control, 2012, 40(24): 107-112.
- [16] 刘爱国, 薛云涛, 胡江鹭, 等. 基于GA优化SVM的风电功率的超短期预测[J]. 电力系统保护与控制, 2015, 43(2): 90-95.  
LIU Aiguo, XUE Yuntao, HU Jiangu, et al. Ultra-short-term wind power forecasting based on SVM optimized by GA[J]. Power System Protection and Control, 2015, 43(2): 90-95.
- [17] 凤志民, 田丽, 吴道林, 等. IGSA优化LSSVM的短期风电功率预测研究[J]. 可再生能源, 2017, 35(11): 1699-1705.  
FENG Zhimin, TIAN Li, WU Daolin, et al. Short-term wind power prediction based on LSSVM optimized by IGSA[J]. Renewable Energy Resources, 2017, 35(11): 1699-1705.
- [18] KARINIOTAKIS G N, STAVRAKAKIS G S, NOGARET E F. Wind power forecasting using advanced neural networks models[J]. IEEE Transactions on Energy Conversion, 1996, 11(4): 762-767.
- [19] 杨茂, 陈郁林. 基于EMD分解和集对分析的风电功率实时预测[J]. 电工技术学报, 2016, 31(21): 86-93.  
YANG Mao, CHEN Yulin. Real-time prediction for wind power based on EMD and set pair analysis[J]. Transactions of China Electrotechnical Society, 2016, 31(21): 86-93.
- [20] 程启明, 陈路, 程尹曼, 等. 基于EEMD和LS-SVM模型的风电功率短期预测方法[J]. 电力自动化设备, 2018, 38(5): 27-35.  
CHENG Qiming, CHEN Lu, CHENG Yinman, et al. Short-term wind power forecasting method based on EEMD and LS-SVM model[J]. Electric Power Automation Equipment, 2018, 38(5): 27-35.
- [21] 叶林, 刘鹏. 基于经验模态分解和支持向量机的短期风电功率组合预测模型[J]. 中国电机工程学报, 2011, 31(31): 102-108.  
YE Lin, LIU Peng. Combined model based on EMD-SVM for short-term wind power prediction[J]. Proceedings of the CSEE, 2011, 31(31): 102-108.
- [22] 刘爱军, 杨育, 李斐, 等. 混沌模拟退火粒子群优化算法研究及应用[J]. 浙江大学学报: 工学版, 2013, 47(10): 1722-1730.  
LIU Aijun, YANG Yu, LI Fei, et al. Chaotic simulated annealing particle swarm optimization algorithm research and its application[J]. Journal of Zhejiang University: Engineering Science, 2013, 47(10): 1722-1730.
- [23] HUANG N E, SHEN Zheng, 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 A: Mathematical, Physical and Engineering Sciences, 1998, 454(1971): 903-995.
- [24] VAPNIK V N. The nature of statistical learning theory[M]. New York: Springer, 1995: 280-292.
- [25] METROPOLIS N, ROSENBLUTH A W, ROSENBLUTH M N, et al. Equation of state calculations by fast computing machines[J]. Journal of Chemical Physics, 1953, 21(6): 1087-1092.

收稿日期: 2019-04-24; 修回日期: 2019-08-09

作者简介:

赵倩(1993—), 女, 硕士研究生, 研究方向为风电功率超短期预测; E-mail: 290807480@qq.com

黄景涛(1977—), 男, 通信作者, 博士, 副教授, 研究方向为数据驱动建模与优化。E-mail: jthuang\_haust@163.com

(编辑 许威)