

DOI: 10.7667/PSPC180358

# 基于混合粒子群算法和多分位鲁棒极限学习机的 短期风速预测方法

鲁迪, 王星华, 贺小平

(广东工业大学自动化学院, 广东 广州 510006)

**摘要:** 为实现高精度的短期风速预测, 提出一种基于混合粒子群算法和多分位鲁棒极限学习机的短期风速预测方法。在信号处理阶段, 利用时变滤波经验模态分解技术将原始风速序列分解为若干子模式以降低其不稳定性。然后采用混合粒子群算法对每一个子模式进行特征提取, 接着利用多分位鲁棒极限学习机分别建立预测模型并利用混合粒子群算法进行参数优化, 最后对每个子模式的预测值进行聚合计算得到最终的预测结果。仿真结果表明: 在考虑使用混合粒子群算法进行特征提取和模型参数优化后, 所提方法具有更高的预测精度。同时基于时变滤波法的经验模态分解技术能够进一步提高预测准确性。

**关键词:** 短期风速预测; 多分位鲁棒极限学习机; 混合粒子群算法; 时变滤波经验模态分解

## Hybrid population particle algorithm and multi-quantile robust extreme learning machine based short-term wind speed forecasting

LU Di, WANG Xinghua, HE Xiaoping

(School of Automation, Guangdong University of Technology, Guangzhou 510006, China)

**Abstract:** In order to achieve short-term wind speed prediction with high accuracy, this paper proposes a Hybrid Population Particle Algorithm (HPPA) and multi-Quantile Robust Extreme Learning Machine (QR-ORELM) based short-term wind speed forecasting. In signal processing stage, it adopts a Time Adaptive Filter based Empirical Mode Decomposition (TVF-EMD) to decompose the original wind speed series into several Intrinsic Mode Functions (IMFs) to decrease the volatility. Then HPPA is used to extract the features of each IMF, and QR-ORELM is used to build their forecasting models respectively and the parameters are optimized by HPPA. Finally, the eventual result can be obtained through aggregating the prediction value of each IMF. Simulation results show that after adopting HPPA for feature selection and model parameter optimization, the proposed hybrid method has higher prediction accuracy. Meanwhile, TVF-EMD based Wind Speed Forecasting (WSF) methods could further improve the predicting accuracy.

This work is supported by National Natural Science Foundation of China (No. 51707041) and Science and Technology Project of China Southern Power Grid (No. GDKJXM20162087).

**Key words:** short-term wind speed forecasting; multi-quantile robust extreme learning machine; hybrid population particle algorithm; time adaptive filter based empirical mode decomposition

## 0 引言

短期风速预测以几小时或几分钟为运行周期, 对电力系统发电计划和经济调度具有重要的意义。风能供应商可以根据准确的超短期风速预测结果做出正确的竞价策略以获得最大的利润, 系统运行者

也可以据此为系统运行做出合理的规划以减少不必要的电力损失<sup>[1-2]</sup>。然而, 风的随机性和波动性特点使得风速预测的难度加大, 如何准确地获取这种非线性关系进行风速预测, 对电网的实时调度、供电系统可靠性和风机控制都具有重大意义<sup>[2-3]</sup>。目前有大量的文献在风速预测领域进行了讨论与研究, 常见的风速预测模型或方法可以分为以下四类: (1) 物理模型, 通常以数值天气预报(Numerical Weather

Prediction, NWP)作为风速预测模型的输入变量来预测未来的风速值。鉴于国内数值天气预报无法获取实时的更新状态,所以此类模型更适用于中长期的风速预测<sup>[4-5]</sup>; (2) 人工智能方法,如神经网络(Artificial Neural Network, ANN)<sup>[6-8]</sup>、支撑向量机(Support Vector Machine, SVM)<sup>[9-10]</sup>和极限学习机(Extreme Learning Machine, ELM)<sup>[11-12]</sup>,通常利用历史风速值来训练出最小的预测误差,具有较好的非线性映射、泛化和自我学习能力,但是此类模型非常依赖参数的整定; (3) 统计学模型,如自回归(Autoregressive, AR)<sup>[13]</sup>和随机波动模型<sup>[14]</sup>,在风速预测方面也得到广泛研究和应用,但是其模型需假定风速时间序列服从正态分布或者其随机成分服从某种分布,而实际风速却具有高随机性,其随机部分不一定符合特定的分布规律,导致预测误差的产生; (4) 混合模型,则是将上述的单个预测方法、信号分解以及优化算法融合在一起进行风速预测<sup>[15-16]</sup>,此类模型保留单个方法优良性能的同时,对存在的缺陷进行相互补充,极大地提高了风速预测精度。

因此,本文提出一种基于混合粒子群算法(HPPA)和多分位鲁棒极限学习机(QR-ORELM)的短期风速预测模型。在信号处理阶段,利用基于时变滤波经验模态分解技术(TVF-EMD)将原始的风速序列分解为若干子模式以降低其不稳定性。对于每个子模式,首先采用混合粒子群算法(HPPA)进行特征提取,接着利用多分位鲁棒极限学习机分别建立预测模型并使用 HPPA 进行参数优化,然后对每个子模式的预测值进行聚合计算得到最终的预测结果。实例证明本文所提模型是可行和有效的。

## 1 方法介绍

### 1.1 基于 EMD 的时变滤波(TVF-EMD)

原始 EMD 的缺点主要在于难以分离出处于倍频区间的信号(分离问题)以及容易出现间歇性的噪音(间歇性问题),从而导致分解出的 IMFs 出现模式混叠的现象。文献[17]提出一种 TVF-EMD 方法同时对分离问题和间歇性问题进行处理,能够通过调整局部截止频率来解决间歇性的问题,然后再根据设定的迭代中止条件对信号进行筛选,直至分解出满足要求的局部窄带信号,与现有的模式分解技术相比, TVF-EMD 的信号分解能力较强,算法的详细介绍见文献[17]。

### 1.2 混合粒子群算法(HPPA)

本文所提的 HPPA 包括二进制粒子群重力搜索法(Binary Particle Swarmoptimization Gravitational

Search Algorithm, BPSOGSA)和 PSO GSA 两个部分,其中 BPSOGSA 用于对预测模型输入变量进行特征提取, PSO GSA 则对 QR-ORELM 网络输入权值和隐含层节点偏差进行优化。

#### 1.2.1 PSO GSA

PSOGSA 算法综合了粒子群算法(PSO)<sup>[18]</sup>的社会认知能力和万有引力算法(GSA)<sup>[19]</sup>的局部搜索能力<sup>[18]</sup>,其原理如下。

假定 PSO GSA 对  $d$  维问题进行搜索,初始搜索单元个数设置为  $N$ ,第  $i$  个粒子的位置向量和速度向量分别用  $\mathbf{X}_i$  和  $\mathbf{V}_i$  表示,在迭代过程中,其位置和速度会随着搜索的最优值  $p_{ibest}$  和  $p_{gbest}$  进行自动调整,调整公式为

$$\begin{cases} \mathbf{V}_i(k+1) = w \times \mathbf{V}_i(k) + c'_1 \times r'_1 \times ac_i(k) + \\ \quad c'_2 \times r'_2 \times (g_{best} - \mathbf{X}_i(k)) \\ \mathbf{X}_i(k+1) = \mathbf{X}_i(k) + \mathbf{V}_i(k) \end{cases} \quad (1)$$

其中:  $\mathbf{V}_i(k)$  是第  $i$  个个体在第  $k$  次迭代的速度;  $\mathbf{X}_i(k)$  为第  $i$  个个体在第  $k$  次迭代的位置;  $c'_1$  和  $c'_2$  是迭代中的加速度系数;  $r'_1$  和  $r'_2$  是[0,1]内的随机数;  $g_{best}$  是第  $k$  次迭代的最优解;  $w$  为权值函数;  $ac_i(k)$  是第  $i$  个个体在第  $k$  次迭代的加速度<sup>[18]</sup>。

#### 1.2.2 BPSOGSA

BPSOGSA 主要是针对二进制空间的搜索问题<sup>[20]</sup>,通过将式(1)的速度和位置更新公式进行改进,使用双曲正切函数将速度转换成一个概率问题,如式(2)所示。

$$S(v_i^d(t)) = |\tanh(v_i^d(t))| \quad (2)$$

基于所得到的速度概率  $S(v_i^d(t))$ ,通过式(3)对搜索个体的速度进行更新,以此实现对二进制空间的全局搜索。

$$\begin{cases} x_{i,j}^d(t+1) = \text{complement}(x_{i,j}^d(t)), \\ \quad \text{rand} < S(v_{i,j}^d(t+1)) \\ x_{i,j}^d(t+1) = x_{i,j}^d(t), \text{ else} \end{cases} \quad (3)$$

其中:  $x_{i,j}^d(t)$  的值取 0 或者 1; 函数  $\text{complement}(\cdot)$  代表逻辑的否定。

### 1.3 分位鲁棒极限学习机(QR-ORELM)

#### 1.3.1 混合模型的建立

ORELM 是在原始 ELM 的基础上进行误差调节,通过输出权值和偏差进行最小化约束来提高模型的鲁棒性,现以单隐含层的鲁棒极限学习机为例介绍如下<sup>[21]</sup>。

$$\sum_{i=1}^{\tilde{N}} \beta_i g(\mathbf{w}_i \cdot \mathbf{x}_j + \mathbf{b}_i) = y_j, j = 1, 2, \dots, N \quad (4)$$

其中:  $\mathbf{x}_i = [x_{i1}, x_{i2}, \dots, x_{in}]$  是给定的输入变量;  $y_i$  为相应的解释变量;  $\mathbf{w}_i = [w_{i1}, w_{i2}, \dots, w_{in}]^T$  是第  $i$  个隐含层神经元和输入变量之间的权值系数;  $\mathbf{b}_i = [b_{i1}, b_{i2}, \dots, b_{in}]^T$  是第  $i$  个隐含层节点的偏差;  $\boldsymbol{\beta}_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{in}]^T$  为连接第  $i$  个隐含层神经元和输出层的权值;  $g(x)$  为激励函数。未知参数  $\boldsymbol{\beta}$  可以通过最小化下述的受约束的凸优化问题进行获取:

$$\begin{cases} \min_{\boldsymbol{\beta}} \|\mathbf{e}\|_1 + \frac{1}{\gamma} \|\boldsymbol{\beta}\|_2^2 \\ \text{s.t. } \mathbf{e} = \mathbf{y} - \mathbf{H}\boldsymbol{\beta} \end{cases} \quad (5)$$

其中,  $\mathbf{H}$  是隐含层的输出矩阵, 有  $\mathbf{H}(w_1, \dots, w_{\bar{N}}, x_1, \dots, x_N, b_1, \dots, b_{\bar{N}}) =$

$$\begin{bmatrix} g(w_1 \cdot x_1 + b_1) & \dots & g(w_{\bar{N}} \cdot x_1 + b_{\bar{N}}) \\ \vdots & & \vdots \\ g(w_1 \cdot x_N + b_1) & \dots & g(w_{\bar{N}} \cdot x_N + b_{\bar{N}}) \end{bmatrix}_{N \times \bar{N}}.$$

由于 ORELM 模型固定, 预测值单一, 为获取更丰富的负荷预测信息, 将分位回归(QR)和 ORELM 结合在一起, 实现“多分位-多场景”灵活预测 QR-ORELM 模型, 其结构可以表示为

$$\mathbf{q}_\tau = \boldsymbol{\omega}_\tau^T \mathbf{u} + \boldsymbol{\beta}_\tau^T \mathbf{H} \quad (6)$$

式中:  $\mathbf{q}_\tau$  是  $\tau$  分位下的预测值  $\tau \in [0, 1]$ ;  $\boldsymbol{\omega}_\tau^T \mathbf{u}$  是分位回归的影响因子,  $\boldsymbol{\omega}$  是线性分位回归模型的参数向量,  $\mathbf{u}$  是模型的输入变量, 有  $\mathbf{u} = \mathbf{x}$ 。

### 1.3.2 混合模型的估计

混合模型的未知参数  $\boldsymbol{\beta}_\tau$  和  $\boldsymbol{\omega}_\tau$  的求解可以参照 ORELM, 首先建立目标损失函数如式(7)。

$$\min_{\boldsymbol{\beta}_\tau, \boldsymbol{\omega}_\tau} \frac{1}{2} \|\boldsymbol{\beta}_\tau\|_2^2 + C \sum_{t=1}^k \rho_\tau(y_t - \boldsymbol{\omega}_\tau^T \mathbf{x}_t - \boldsymbol{\beta}_\tau^T h(\mathbf{x}_t)) \quad (7)$$

其中:  $C$  是惩罚系数;  $y_t$  是  $t$  时刻的目标值;  $\rho_\tau(\theta)$  是检验函数<sup>[21]</sup>;  $h(\mathbf{x}_t)$  对应于矩阵  $\mathbf{H}$  的每一列元素。引入松弛变量, 构建问题(7)的拉格朗日函数, 即

$$\begin{aligned} L_\mu(\mathbf{e}, \boldsymbol{\beta}_\tau, \boldsymbol{\omega}_\tau, \lambda) = & \frac{1}{C} \|\boldsymbol{\beta}_\tau\|_2^2 + \sum_{\substack{\tau \\ |y_t \geq \boldsymbol{\omega}_\tau^T \mathbf{x}_t + \boldsymbol{\beta}_\tau^T h(\mathbf{x}_t)}} \tau |y_t - \boldsymbol{\omega}_\tau^T \mathbf{x}_t - \boldsymbol{\beta}_\tau^T h(\mathbf{x}_t)| + \\ & \sum_{\substack{\tau \\ |y_t < \boldsymbol{\omega}_\tau^T \mathbf{x}_t + \boldsymbol{\beta}_\tau^T h(\mathbf{x}_t)}} (1-\tau) |y_t - \boldsymbol{\omega}_\tau^T \mathbf{x}_t - \boldsymbol{\beta}_\tau^T h(\mathbf{x}_t)| + \\ & \lambda^T (y_t - \boldsymbol{\omega}_\tau^T \mathbf{x}_t - \boldsymbol{\beta}_\tau^T h(\mathbf{x}_t) - e) + \\ & \frac{2}{\mu} \sum_{t=1}^k (y_t - \boldsymbol{\omega}_\tau^T \mathbf{x}_t - \boldsymbol{\beta}_\tau^T h(\mathbf{x}_t) - e)^2 = 0 \end{aligned} \quad (8)$$

其中:  $\lambda \in R^n$  是拉格朗日向量乘子;  $\mu$  是惩罚系数, 并且有  $\mu = 2N/\|\mathbf{y}\|_1$ ; 通过对参数  $\boldsymbol{\beta}_\tau$  和  $\boldsymbol{\omega}_\tau$  求偏导得到函数的最优解, 参数的迭代求解过程如式(9)所示。

$$\begin{cases} \boldsymbol{\beta}_{k+1} = (\mathbf{H}^T \mathbf{H} + 2/C\mu \mathbf{I})^{-1} \mathbf{H}^T \mathbf{U} (\mathbf{U}^T \mathbf{U})^{-1} \mathbf{U}^T (\mathbf{y} - \mathbf{e}_k + \lambda_k / \mu) - \\ \quad \mathbf{U} (\mathbf{U}^T \mathbf{U})^{-1} \mathbf{U}^T (\mathbf{y} - \mathbf{e}_k + \lambda_k / \mu), \quad \mathbf{U} = (\mathbf{1}, \mathbf{x}_k^T) \\ \boldsymbol{\omega}_{k+1} = (\mathbf{U}^T \mathbf{U})^{-1} \mathbf{U}^T (\mathbf{y} - \mathbf{H}\boldsymbol{\beta}_{k+1} - \mathbf{e}_k + \lambda_k / \mu) \\ \lambda_{k+1} = \lambda_k + \mu (\mathbf{y} - \mathbf{H}\boldsymbol{\beta}_{k+1} - \mathbf{U}\boldsymbol{\omega}_{k+1} - \mathbf{e}_{k+1}) \end{cases} \quad (9)$$

其中,

$$\begin{aligned} \mathbf{e}_{k+1} = & \text{shrink}(\mathbf{y} - \mathbf{H}\boldsymbol{\beta}_{k+1} - \mathbf{e}_k + \lambda_k / \mu, 1/\mu) \triangleq \\ & \max\{|\mathbf{y} - \mathbf{H}\boldsymbol{\beta}_{k+1} - \mathbf{U}\boldsymbol{\omega}_{k+1} + \lambda_k / \mu - 1/\mu, 0|\} \circ \\ & \text{sign}(\mathbf{y} - \mathbf{H}\boldsymbol{\beta}_{k+1} - \mathbf{U}\boldsymbol{\omega}_{k+1} + \lambda_k / \mu) \end{aligned} \quad (10)$$

参数迭代过程停止条件为

$$|L_{\mu, k+1} - L_{\mu, k}| \leq \varepsilon \quad (11)$$

其中:  $L_{\mu, k+1}$  和  $L_{\mu, k}$  代表式(11)中第  $k$  和  $k+1$  次迭代损失函数值;  $\varepsilon$  是阈值, 通过多次迭代, 即可确定混合模型的结构参数。

### 1.3.3 参数的选择

实际应用中, QR-ORELM 的隐含层节点个数  $L$  和惩罚系数  $C$  需要提前给定, 这两个参数的选择直接影响着预测的精度, 本文采用广义逼近交叉验证法(Generalized Approximate Cross-Validation, GACV)对其进行选择, 计算如式(12)。

$$\begin{aligned} \text{GACV}(\eta) = & \frac{\sum_{t=1}^N \rho_\tau(y_t - q_\tau(\mathbf{x}_t))}{N - df} = \\ & \frac{\sum_{t=1}^N \rho_\tau(y_t - \boldsymbol{\omega}_\tau^T \mathbf{x}_t - \boldsymbol{\beta}_\tau^T h(\mathbf{x}_t))}{N - df} \end{aligned} \quad (12)$$

其中:  $\eta = (L, C)$  为待确定的参数;  $df$  是模型的有效维数, 通过最小化式(12)即可得到最优参数  $\eta$ 。

## 2 短期风速预测模型

### 2.1 模型评价指标

为了评价本文所提混合风速预测模型的预测性能, 本文采用平均绝对百分比误差(Mean Absolute Percentage Error, MAPE)、绝对误差均值(Mean Absolute Error, MAE)和均方根误差(Root Mean-Squared Error, RMSE)来定量评价模型的性能, 三种评价指标定义如下。

$$\text{MAPE} = \frac{1}{M} \sum_{t=1}^M \left| \frac{p_{\text{real}}^t - p_{\text{pre}}^t}{p_{\text{real}}^t} \right| \times 100\% \quad (13)$$

$$\text{MAE} = \frac{1}{M} \sum_{t=1}^M |p_{\text{real}}^t - p_{\text{pre}}^t| \quad (14)$$

$$\text{RMSE} = \sqrt{\frac{1}{M} \sum_{t=1}^M (p_{\text{real}}^t - p_{\text{pre}}^t)^2} \quad (15)$$

其中： $p_{real}^t$  和  $p_{pre}^t$  分别为风速的实测值和预测值。通常，MAPE、MAE、RMSE 的值越小说明模型的预测精度更高。

### 2.2 风速预测流程

基于混合粒子群算法和多分位鲁棒极限学习机的混合风速预测模型的整体框架如图 1 所示，其预测流程如下。

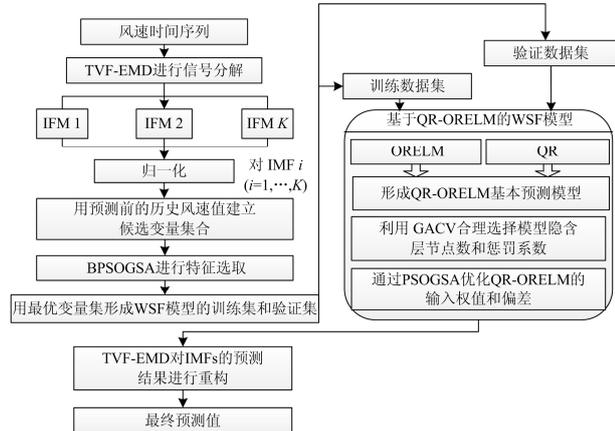


图 1 短期风速混合预测模型整体框架

Fig. 1 Overall structure of the hybrid WSF model

1) 利用 TVF-EMD 将原始风速时间序列进行分解，再将每一个风速子序列进行归一化。

2) 选用预测前一定时间窗长度的历史风速值作为候选的特征变量，用 BPSOGSA 算法进行特征选取，选出最相关的特征变量集作为风速预测模型的训练和验证输入集。

3) 对每一个归一化后的子序列进行训练，建立 QR-ORELM 模型，其中隐含层节点个数和惩罚系数通过 GACV 进行选取，而输入权值和偏差则通过 PSOGSA 进行优化。

4) 用验证集对训练出的每个子序列模型进行验证，最后通过加权集成每个预测结果生成最后的预测值。

## 3 实例分析

本文以国家可再生能源实验室(NREL)提供的某向岸风电场 2006 年的实测风速时间序列作为研究对象，对本文所提的预测模型进行训练和验证。

### 3.1 数据来源

为了分析季节对风速预测的影响，选取四月、七月、十月和一月作为每个季节的典型月份分别建立不同的预测模型，该风电场不同季节的风速时间序列及其统计信息分别如图 2 和表 1 所示。风速数据的采样频率 10 min，因此四个月的样本点个数分别为 4 320，4 464，4 464 和 4 464，随机选取每

个季节 700 个样本点进行分析(前 600 个点作为训练集，剩余的 100 个样本点作为测试集)。

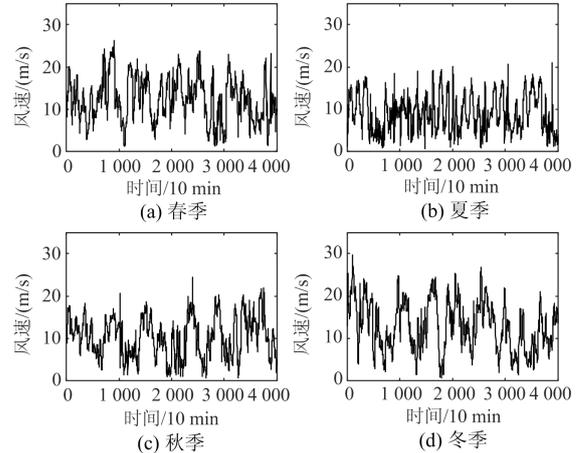


图 2 不同季节典型月份的风速序列

Fig. 2 Wind speed series of typical month among different seasons

表 1 训练数据集和验证数据集的统计信息

Table 1 Statistical information of the training data set and the testing data

统计指标	风速			
	1月(冬)	4月(春)	7月(夏)	10月(秋)
最小值/(m/s)	0.43	1.35	0.75	0.84
最大值/(m/s)	29.71	26.24	22.01	24.48
均值	12.80	12.09	9.10	10.57
方差	5.85	5.10	4.76	4.18

### 3.2 模型参数设置

为验证本文提出 QR-ORELM 模型预测性能的优越性，将其与持久模型(Persistence Model, PM)，支撑向量分位回归模型(Support Vector Quantile Regression, SVQR)、鲁棒极限学习机(Outlier-Robust ELM, ORELM)和线性分位回归模型(Linear Quantile Regression, LQR)的预测效果进行对比，并选取 3 个不同分位  $\tau = 0.1, 0.5, 0.9$  进行研究和分析，以便选择出最优的预测模型。每个模型使用同样的训练样本集和验证样本集，并且进行多次实验求平均值作为最终的预测结果，各模型参数初始化如表 2 所示。

### 3.3 风速时间信号分解与特征提取

参数设定完成后需要利用 TVF-EMD 和 HPPA 对风速样本时间序列进行信号分解和特征提取，为验证 TVF-EMD 分解性能，将其与 EMD 分解进行对比。选取 4 月份的风速时间序列为例，原始风速见图 2(a)所示，通过 TVF-EMD 和 EMD 分解后各子模式见图 3 和图 4。然后对所有的 IMFs 进行特征变量的提取，选取预测时刻前 2 个小时内的历史风速实测值作为候选变量，利用 BPSOGSA 提取出最

相关的输入特征, 特征提取结果见表 3, 从中可以看出离预测点越近的点被选中的可能性越高, 其相关性越强; 其中 IMFs 信号越复杂, 最终确定的特征越多。

表 2 预测模型参数初始化

Table 2 Parameter initialization of forecasting models

算法	参数	设定值
HPPA	最大迭代次数	100
	种群个数	50
	初始重力常数	1
	衰减系数	20
QR-ORELM	迭代阈值	0.001
	隐含层节点个数	$L=[5, 10, \dots, 40]$
	惩罚系数	$C=[2^{-10}, \dots, 2^9, 2^{10}]$
ORELM	隐含层节点个数	$L=[5, 10, \dots, 40]$
	惩罚系数	$C=[2^{-10}, \dots, 2^{20}, 2^{30}]$
TVF-EMD	带宽阈值	0.25
	B 样条阶数	26
SVQR	惩罚参数	$C_p=[2^{-8}, \dots, 2^7, 2^8]$
	核参数	$\sigma=[2^{-5}, \dots, 2^4, 2^5]$

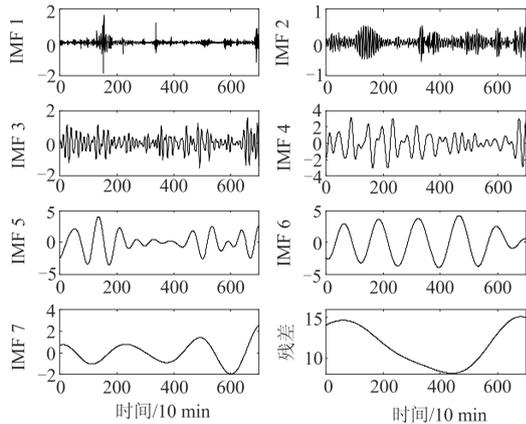


图 3 利用 TVF-EMD 分解后的风速子序列

Fig. 3 Wind speed sub-series decomposed by TVF-EMD

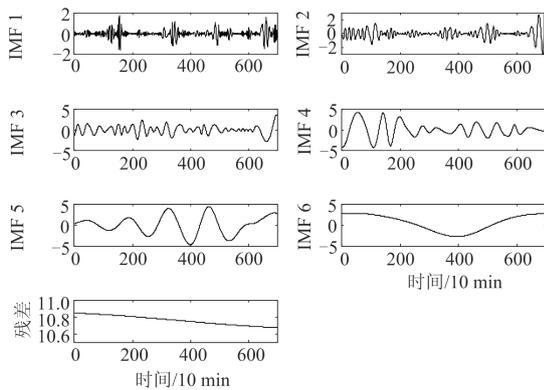


图 4 利用 EMD 分解后的风速子序列

Fig. 4 Wind speed sub-series decomposed by EMD

表 3 BPSOGSA 的特征选取结果

Table 3 Feature selection results with BPSOGSA

风速序列	候选变量											
	1	2	3	4	5	6	7	8	9	10	11	12
信号	1	1	0	1	0	0	0	1	1	1	1	1
IMF 1	1	1	1	1	1	1	1	1	1	1	1	1
IMF 2	1	1	1	1	1	1	1	1	1	1	1	1
IMF 3	1	1	1	1	1	1	1	1	1	1	1	1
IMF 4	1	1	0	0	1	0	1	0	1	1	1	1
IMF 5	1	0	0	1	1	1	0	1	1	1	1	1
IMF 6	1	0	1	0	0	1	1	1	0	1	1	1
IMF 7	0	1	1	0	0	0	0	0	0	1	0	1
误差	1	1	0	1	1	1	1	0	0	0	1	1
IMF 1	0	0	1	0	0	1	1	1	1	1	1	1
IMF 2	0	0	1	0	0	0	1	1	1	1	1	1
IMF 3	1	1	1	1	1	1	1	1	1	1	1	1
IMF 4	0	1	1	1	1	1	0	1	1	1	1	1
IMF 5	0	1	0	1	0	0	0	0	1	1	1	1
IMF 6	1	0	0	1	0	0	0	0	0	0	1	1
误差	0	0	0	0	0	0	0	0	0	0	1	1

备注: “0” 代表未选中, “1” 代表选中

### 3.4 结果分析与对比

进行特征提取和参数优化后基于 TVF-EMD 和 EMD 的各个模型的预测指标分别见表 4 和表 5, 从中可以看出:

- 1) PM 和 ORELM 的预测不涉及分位变化, 两者的预测性能始终最差。
- 2) QR-ORELM 总是能够获得最低的 MAPE、MAE 和 RMSE, 说明本文所提模型的高效性。
- 3) 基于 TVF-EMD 的模型比基于 EMD 的模型预测性能好, 反映 TVF-EMD 对风速分解的优越性。

表 4 基于 TVF-EMD 和特征提取的预测模型的性能

Table 4 Forecasting performance of TVF-EMD based WSF models with feature selection technique

模型	指标			
	MAPE	MAE	RMSE	
$\tau=0.1$	QR-ORELM	<b>0.237 3</b>	<b>0.037</b>	<b>0.072</b>
	SVQR	0.251 8	0.039 2	0.073 4
	LQR	0.435 1	0.068 1	0.137 7
$\tau=0.5$	QR-ORELM	<b>0.244 7</b>	<b>0.038 5</b>	<b>0.074 6</b>
	SVQR	0.251 8	0.039 2	0.073 4
	LQR	0.435 7	0.068 1	0.137 8
$\tau=0.9$	QR-ORELM	<b>0.247 4</b>	<b>0.013 2</b>	<b>0.023 8</b>
	SVQR	0.251 8	0.039 2	0.073 4
	LQR	0.434 2	0.067 9	0.137 5
	ORELM	0.540 5	0.085 4	0.152 2
PM	2.564 8	0.375 2	0.593 7	

表 5 基于 EMD 和特征提取的预测模型的性能  
Table 5 Forecasting performance of EMD based WSF models with feature selection technique

模型	指标			
	MAPE	MAE	RMSE	
$\tau=0.1$	QR-ORELM	<b>1.361 1</b>	<b>0.215 1</b>	<b>0.363 9</b>
	SVQR	1.550 1	0.233 7	0.346 3
	LQR	1.442 3	0.220 9	0.358 3
$\tau=0.5$	QR-ORELM	<b>1.359 9</b>	<b>0.203 9</b>	<b>0.342 7</b>
	SVQR	1.55	0.233 6	0.346 3
	LQR	1.442 7	0.220 7	0.356 5
$\tau=0.9$	QR-ORELM	<b>1.358 3</b>	<b>0.209 9</b>	<b>0.362 6</b>
	SVQR	1.550 1	0.233 7	0.346 3
	LQR	1.473 1	0.224 5	0.359
	ORELM	1.612 9	0.248 8	0.435 4
	PM	3.062 7	0.321 9	0.469

4) QR-ORELM 模型的预测指标随着不同的分位而变化,在不同的分位值的情况下,其预测精度的变化相比 SVQR 和 LQR 更明显。而在相同分位值下,QR-ORELM 的预测性能比基准模型有优势。

考虑到风速季节性特征所带来的复杂性和不确定性,为了进一步验证本文所提出的 QR-ORELM 模型对不同季节风速预测的有效性,利用上述算法对 4 个典型月份的风速样本进行仿真分析,得到的结果见表 6 所示,对比表 6 中各算法的季节预测指标可知:

1) QR-ORELM 模型在此数据样本下冬季的预测准确度始终最差,如在  $\tau=0.1$  时,其 MAPE 为 1.148 0%,其余依次排序为夏季、春季和秋季,其 MAPE 值分别为 0.543 1%、0.237 3%、和 0.095 7%,而从表 1 的样本统计信息的方差、最大值和最小值看出,在所述数据样本中冬季风速的不确定性和随机性更大,而秋季正好相反,以此造成预测精度的差异。

2) QR-ORELM 和 SVQR 都具有较好的预测性能,而 QR-ORELM 的预测精度评价指标 MAPE、MAE、RMSE 稍微优于 SVQR,说明融合分位回归与神经网络的混合模型的有效性,也体现了 QR-ORELM 对季节性特征具有较强的获取和处理能力。

3) QR-ORELM 模型的预测指标随着分位数的变化最明显,但是随着样本的变化,其最优预测精度不会固定在某个分位下,如在所述数据样本中春季在  $\tau=0.1$  时预测效果最优,而冬季则在  $\tau=0.9$  时预测效果最优。

综上所述,本文所提 QR-ORELM 模型具有较好的预测性能,能够实现不同分位下的高精度短期风速预测,基于本文所提模型的季节预测效果图见图 5,从图 5 也可以看出,QR-ORELM 模型对本文所述季节性样本具有较好的拟合效果,显示出较高的预测精度。

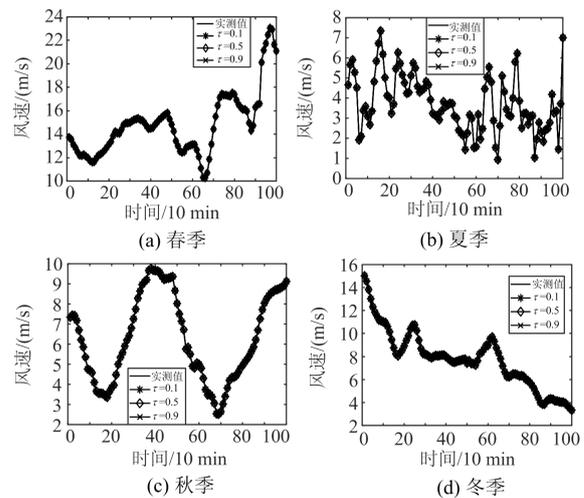


图 5 不同分位下的季节性风速预测图

Fig. 5 Diagram of prediction results at different quantiles in four seasons

表 6 不同模型的季节性风速预测结果

Table 6 Seasonal WSF performance results of different models

方法	春季			夏季			秋季			冬季			
	MAPE/ %	MAE/ (m/s)	RMSE/ (m/s)	MAPE/ %	MAE/ (m/s)	RMSE/ (m/s)	MAPE/ %	MAE/ (m/s)	RMSE/ (m/s)	MAPE/ %	MAE/ (m/s)	RMSE/ (m/s)	
$\tau=0.1$	QR-ORELM	<b>0.237 3</b>	<b>0.037 0</b>	<b>0.072 0</b>	<b>0.543 1</b>	<b>0.016 3</b>	<b>0.023 3</b>	<b>0.005 0</b>	<b>0.006 9</b>	<b>1.148 0</b>	<b>0.071 2</b>	<b>0.098 4</b>	
	SVQR	0.251 8	0.039 2	0.073 4	0.018 8	0.025 2	1.961 6	0.280 2	0.015 2	0.016 3	1.167 4	0.075 3	0.100 7
	LQR	0.435 1	0.068 1	0.137 7	1.961 6	0.057 7	0.078 2	0.248 6	0.013 7	0.017 2	0.849 5	0.062 0	0.078 5
$\tau=0.5$	QR-ORELM	<b>0.245 3</b>	<b>0.038 5</b>	<b>0.075 4</b>	<b>0.651 3</b>	<b>0.019 0</b>	<b>0.026 7</b>	<b>0.094 6</b>	<b>0.004 9</b>	<b>0.006 7</b>	<b>1.397 1</b>	<b>0.079 9</b>	<b>0.124 4</b>
	SVQR	0.251 8	0.039 2	0.073 4	0.662 6	0.019 2	0.026 9	0.280 7	0.015 2	0.016 3	1.445 1	0.082 3	0.139 3
	LQR	0.435 7	0.068 1	0.137 8	1.945 0	0.077 3	0.146 4	0.241 5	0.013 5	0.017 1	0.849 0	0.062 0	0.078 5
$\tau=0.9$	QR-ORELM	<b>0.251 9</b>	<b>0.040 5</b>	<b>0.076 8</b>	<b>0.603 0</b>	<b>0.017 9</b>	<b>0.023 8</b>	<b>0.098 7</b>	<b>0.005 2</b>	<b>0.007 0</b>	<b>0.736 1</b>	<b>0.049 4</b>	<b>0.061 7</b>
	SVQR	0.251 8	0.039 2	0.073 4	0.642 7	0.018 8	0.025 2	0.279 9	0.015 2	0.016 3	0.774 0	0.065 1	0.069 3
	LQR	0.434 2	0.067 9	0.137 5	1.932 7	0.076 9	0.148 1	0.243 6	0.013 5	0.017 1	0.848 4	0.061 9	0.078 4
	ORELM	0.540 5	0.085 4	0.152 2	2.458 4	0.077 7	0.102 1	0.029 67	0.016 6	0.021 9	1.330 8	0.072 5	0.132 2
	PM	2.564 8	0.375 2	0.593 7	24.97 0	0.750 0	1.000 8	4.706 6	0.256 8	0.322 8	3.151 6	0.254 0	0.333 9

## 4 结论

本文的创新点在于提出了一种分位鲁棒极限学习机方法, 并结合 TVF-EMD 信号分解技术、HPPA 特征提取和参数优化形成一种超短期风速预测混合模型, 通过实例分析得出的结论如下:

1) 本文所提的 QR-ORELM 模型在不同分位下对不同季节风速的预测性能明显优于基准风速预测模型。

2) 经 TVF-EMD 分解后的风速预测精度比经 EMD 分解的风速预测精度高, 反映了 TVF-EMD 对于风速分解的优越性。

3) 本文所提模型能够实现不同分位下的高精度短期风速预测, 且能够随着分位变化产生较明显的预测值变动, 进一步说明了 QR-ORELM 的有效性。

考虑最优预测精度不会固定在某一个分位上, 而是随着样本的变化而不同。为充分利用上述多个分位下的预测值, 此后将考虑对不同分位下的预测值进行加权整合, 形成加权分位回归鲁棒极限学习机来进行短期风速预测, 以给系统决策者提供更加全面而综合的风速预测值信息。

## 参考文献

- [1] 叶瑞丽, 郭志忠, 刘瑞叶, 等. 基于小波包分解和改进 Elman 神经网络的风电场风速和风电功率预测[J]. 电工技术学报, 2017, 32(21): 107-115.  
YE Ruili, GUO Zhizhong, LIU Ruiye, et al. Wind speed and wind power forecasting method based on wavelet packet decomposition and improved elman neural network[J]. Transactions of China Electrotechnical Society, 2017, 32(21): 107-115.
- [2] 王静, 李维德. 基于 CEEMD 和 GWO 的超短期风速预测[J]. 电力系统保护与控制, 2018, 46(9): 69-74.  
WANG Jing, LI Weide. Ultra-short-term forecasting of wind speed based on CEEMD and GWO[J]. Power System Protection and Control, 2018, 46(9): 69-74.
- [3] 叶燕飞, 王琦, 陈宁, 等. 考虑时空分布特性的风速预测模型[J]. 电力系统保护与控制, 2017, 45(4): 114-120.  
YE Yanfei, WANG Qi, CHEN Ning, et al. Wind forecast model considering the characteristics of temporal and spatial distribution[J]. Power System Protection and Control, 2017, 45(4): 114-120.
- [4] 杨正瓴, 刘阳, 张泽, 等. 采用最近历史观测值和 PLSR 进行空间相关性超短期风速预测[J]. 电网技术, 2017, 41(6): 1816-1822.  
YANG Zhengling, LIU Yang, ZHANG Ze, et al. Ultra-short-term wind speed prediction with spatial correlation using recent historical observations and PLSR[J]. Power System Technology, 2017, 41(6): 1816-1822.
- [5] SONG Z, JIANG Y, ZHANG Z. Short-term wind speed forecasting with Markov-switching model[J]. Applied Energy, 2014, 130(5): 103-112.
- [6] LIU H, TIAN H, LI Y, et al. Comparison of four adaboost algorithm based artificial neural works in wind speed predictions[J]. Energy Conversion Management, 2015, 92: 67-81.
- [7] 潘超, 秦本双, 何瑶, 等. 基于优化 FCM 聚类的 RELM 风速预测[J]. 电网技术, 2018, 42(3): 842-848.  
PAN Chao, QIN Benshuang, HE Yao, et al. Wind speed forecasting of regularized ELM based on optimized FCM clustering[J]. Power System Technology, 2018, 42(3): 842-848.
- [8] 刘兴杰, 岑添云, 郑文书, 等. 基于模糊粗糙集与改进聚类的神经网络风速预测[J]. 中国电机工程学报, 2014, 34(19): 3162-3169.  
LIU Xingjie, CEN Tianyun, ZHENG Wenshu, et al. Neural network wind speed prediction based on fuzzy rough set and improved clustering[J]. Proceedings of the CSEE, 2014, 34(19): 3162-3169.
- [9] 殷豪, 董朕, 陈云龙. 基于 CEEMD 和膜计算优化支持向量机的风速预测[J]. 电力系统保护与控制, 2017, 45(21): 27-34.  
YIN Hao, DONG Zhen, CHEN Yunlong. Wind speed forecasting based on complementary ensemble empirical mode decomposition and support vector regression optimized by membrane computing optimization[J]. Power System Protection and Control, 2017, 45(21): 27-34.
- [10] ORTIZ-GARCIA E G, SALCEDO-SANZ S, PEREZ-BELLIDO A M, et al. Short-term wind speed prediction in wind farms based on banks of support vector machines[J]. Wind Energy, 2011, 14(2): 193-207.
- [11] ZHANG C, ZHOU J, LI C, et al. A compound structure of ELM based on feature selection and parameter optimization using hybrid backtracking search algorithm for wind speed forecasting[J]. Energy Conversion Management, 2017, 143: 360-376.
- [12] ZHANG K, LUO M. Outlier-robust extreme learning machine for regression problems[J]. Neurocomputing, 2015, 151: 1519-1527.
- [13] 李余琪, 张刚林, 甘敏. 基于函数系数自回归模型的风速时间序列预测[J]. 数学的实践与认识, 2017, 47(8): 162-166.  
LI Yuqi, ZHANG Ganglin, GAN Min. Wind speed

- prediction based on functional coefficient autoregressive models[J]. *Mathematics in Practice and Theory*, 2017, 47(8): 162-166.
- [14] 陈昊, 王玉荣. 基于随机波动模型的短期负荷预测[J]. *电力自动化设备*, 2010, 30(11): 86-89.  
CHEN Hao, WANG Yurong. Short-term load forecasting based on SV model[J]. *Electric Power Automation Equipment*, 2010, 30(11): 86-89.
- [15] 杨茂, 杜刚. 基于 t Location-Scale 分布的风电功率概率预测研究[J]. *中国电力*, 2017, 50(1): 140-145.  
YANG Mao, DU Gang. Wind power probability prediction based on t Location-Scale distribution[J]. *Electric Power*, 2017, 50(1): 140-145.
- [16] 司徒友, 李刚强, 张水平. 基于小波分解和深度信念网络的短期风速预测[J]. *广东电力*, 2017, 30(4): 25-30.  
SITU You, LI Gangqiang, ZHANG Shuiping. Short-term wind speed forecasting based on wavelet decomposition and deep belief network[J]. *Guangdong Electric Power*, 2017, 30(4): 25-30.
- [17] 董朕, 殷豪, 孟安波. 基于混合算法优化神经网络的风电预测模型[J]. *广东电力*, 2017, 30(2): 29-33.  
DONG Zhen, YIN Hao, MENG Anbo. Wind power forecasting model based on optimized neural network of hybrid algorithm[J]. *Guangdong Electric Power*, 2017, 30(2): 29-33.
- [18] 史林军, 唐国庆. 基于改进 PSO 算法的 FESS 的 PI 参数优化[J]. *电力系统保护与控制*, 2010, 38(10): 52-57.  
SHI Linjun, TANG Guoqing. PESS PI parameter optimization by an improved PSO algorithm[J]. *Power System Protection and Control*, 2010, 38(10): 52-57.
- [19] RASHEDI E, NEZAMABADI-POUR H, SARYAZDI S. GSA: a gravitational search algorithm[C] // *International Conference on Computer and Knowledge Engineering*, IEEE, 2012: 390-395.
- [20] MIRJALILI S, HASHIM S Z M. A new hybrid PSO-GSA algorithm for function optimization[C] // *International Conference on Computer and Information Application* IEEE, December 3-5, 2010, Tianjin, China: 374-377.
- [21] 彭显刚, 郑伟钦, 林利祥, 等. 考虑负荷自适应检测和修复的鲁棒极限学习机短期负荷预测方法[J]. *中国电机工程学报*, 2016, 36(23): 6409-6417.  
PENG Xiangang, ZHENG Weiqin, LIN Lixiang, et al. Short-term load forecasting method based on outlier robust extreme learning machine considering adaptive load detection and repair[J]. *Proceedings of the CSEE*, 2016, 36(23): 6409-6417.

收稿日期: 2018-03-30; 修回日期: 2018-06-13

作者简介:

鲁迪(1992—), 女, 硕士研究生, 研究方向为电力系统运行分析和电网规划、大数据在智能电网中的应用; E-mail: dilu.betty@yahoo.com

王星华(1972—), 男, 副教授, 硕士生导师, 研究方向为电力系统自动化、电力系统高级应用软件开发、信息化电力系统等领域的研究和开发。E-mail: riskmouse@163.com

(编辑 葛艳娜)