

基于 EMD 与加权马尔可夫链 QR 法的风电功率区间预测

杨锡运¹, 马 雪¹, 张 洋¹, 张 璜¹, 耿 娜²

(1. 华北电力大学控制与计算机工程学院, 北京 102206; 2. 吉林省电力科学研究院, 长春 130021)

摘 要: 提出一种基于经验模式分解(EMD)、加权马尔可夫链与分位数回归(quantile regression, QR)的风电功率概率区间预测方法。由于风功率数据与风速显著相关, 首先对历史风速进行经验模式分解, 得到不同频率段的风速, 再以不同频率段的风速为样本, 分别对其进行加权马尔可夫链预测, 相加得到最终预测风速。最后将所得的预测风速代入 QR 预测模型, 得到一定置信水平下的风电功率概率区间的上下限。以区间覆盖率和区间平均带宽为评价指标, 与马尔可夫链下的 QR 法和加权马尔可夫链下的 QR 法的对比仿真表明, 提出的基于经验模式分解与加权马尔可夫链下的 QR 法具有风电功率概率区间预测的覆盖率更高, 平均带宽更窄, 精度更好的预测效果。

关键词: 风电功率; 区间预测; 经验模式分解; 加权马尔可夫链; 分位数回归

中图分类号: TM61

文献标志码: A

0 引 言

可持续性发展已成为世界各国的共识, 因此风能作为可再生能源在世界能源开发的占比逐年提升。但是, 由于风力具有不确定性、随机性, 是一种随时间变化而又无法准确估计的不稳定输出能源, 这给利用风能发电的方式造成了极大的挑战^[1]。对风电功率进行有效预测至关重要^[2]。目前国内外学者做了大量研究工作, 主要包括物理法和统计法^[3]。但这些方法都只能得到确定的点预测, 由于各种不确定因素影响, 点预测在实际工程中通常存在误差, 且无法给出预测数值出现的概率及波动范围。为满足电力系统的实际要求, 将概率性区间预测方法引入到风电功率预测中具有重要意义。

经验模式分解(EMD)方法^[4]能以自适应方式提取信号的各分量及变化趋势, 吸取小波分解的多分辨优势^[5], 克服小波分解中需选取小波基的困难^[6]。文献[7]介绍的马尔可夫链模型是目前较受关注的预测法, 该方法通过研究初步概率与转移概率的不同状态来确定数据序列的变化趋势^[8-9], 从而达到预测目的。文献[10]中加权马尔可夫链方法利用了历史数据信息, 在马尔可夫链权重上进行改进。在参考文献[11]中, 利用历史数

据的预测模型是分析置信区间不确定性的常用方法, 该方法基于以下假设: 预测误差遵循高斯分布^[12]。与经验误差统计^[13]不同, 分位数回归不需要误差项的分布, 在大样本领域具有明显的优势, 并且可以对数据的奇异点具备容忍性^[14]。

基于上述分析, 将经验模式分解、马尔可夫链、QR 引入到风功率概率区间预测中。该方法首先对历史风速进行经验模式分解, 得到不同频率段的风速; 再将不同频率段的风速作为样本, 对其分别进行加权马尔可夫链预测, 相加得到预测风速; 代入到 QR 预测模型中得到一定置信水平下的风电功率概率区间的上下限。选择区间覆盖率和区间平均带宽 2 项指标值为评价标准, 与其他方法对比仿真表明, 该方法在预测准确度以及精度方面具有优越性。

1 模型原理的相关理论

1.1 经验模式分解原理

Huang 等^[4]提出经验模式分解方法, 用于处理非线性和非平稳信号, 是一种新的数据分析和处理方法。本质上, 经验模式分解方法是将一个非平滑的时间序列逐渐分解为不同尺度的波动或趋势, 从而获得

不同特征尺度的一系列数据序列。每个序列称为本征模式函数(intrinsic mode function, IMF),原始信号的趋势或均值通常是最低频率的IMF分量。本征模函数必须要满足2个条件:1)数据相对于时间轴是局部对称的,也就是说在任何时间点局部平均值都为零^[5];2)数据系列中,极点和零点的在数量上必须相等或者最多相差1个。

经验模式分解步骤为:1)找到要分解信号的所有极值,然后使用三次样条函数,将它们拟合为这一信号的上下包络线,计算2个包络线上的平均值,计算分解信号值与平均值的差值,记录为 h ;2)如果差值 h 不符合IMF的要求,需要多次重复上述步骤,使得差值 h 符合IMF的要求,如果满足IMF的要求,则将 h 用作原始信号的第1个IMF,并找到原始信号与该IMF之间的差值 r ;3) r 为要分解的信号,重复上述过程,可以参考文献[6]具体的分解过程,直到其余信号满足预定的终止标准,然后终止整个分解过程。经验模式分解的结果可表示为:

$$X(t) = \sum_{i=1}^n C_i(t) + r_n \quad (1)$$

式中, $C_i(t)$ ——IMF分量,代表原始信号中不同特征尺度的信号分量; r_n ——剩余分量,反映原始信号 $X(t)$ 的变化趋势。

因此,经验模式分解可将信号 $X(t)$ 分解成 n 个不同频率的平稳分量IMF和1个趋势项之和。

1.2 马尔可夫链原理

马尔可夫链具备“无后性”与“马尔可夫性”,即未来状态不受过去状态的影响,时间与状态都是离散的,是一种的特殊的随机过程^[7-8]。设有随机过程 $\{X_n\}$ 和离散状态 $S = \{s_0, s_1, \dots, s_n, \dots\}$,如果随机过程在时刻 t 处于状态 s_n ,在时刻 $T(T > t)$ 所处状态与时刻 t 以前的状态无关,即:

$$\begin{aligned} P\{X_{n+1} = s_{n+1} | X_0 = s_0, X_1 = s_1, \dots, X_n = s_n\} \\ = P\{X_{n+1} = s_{n+1} | X_n = s_n\} \end{aligned} \quad (2)$$

则 $\{X_n\}$ 称为马尔可夫链,并记:

$$P_{ij(k)} = P\{X_{n+k} = s_j | X_n = s_i\} \quad (3)$$

式中, $P_{ij(k)}$ ——在初始时刻 n 所处于状态 s_i 的条件下,在时刻 $n+k$ 转移到状态 s_j 的转移概率。

将数据序列分为若干种状态,记为 $s_0, s_1, \dots, s_n, \dots$ 则状态转移概率为:

$$P_{ij(k)} = \frac{M_{ij(k)}}{M_i} \quad (4)$$

式中, $M_{ij(k)}$ ——数据序列从状态 s_i 经过 k 步到状态 s_j 的转移数据数量; M_i ——数据序列处于状态 s_i 的原始数据数量^[9]。

构成相应的第 k 步的状态转移概率矩阵:

$$P^k = \begin{bmatrix} P_{11(k)} & P_{12(k)} & \dots & P_{1n(k)} \\ P_{21(k)} & P_{22(k)} & \dots & P_{2n(k)} \\ \vdots & \vdots & \ddots & \vdots \\ P_{n1(k)} & P_{n2(k)} & \dots & P_{nn(k)} \end{bmatrix} \quad (5)$$

马尔可夫的预测过程可由其转移概率矩阵和初始分布向量确定。状态转移概率矩阵描述该马尔可夫预测模型的动态特征,设其初始状态 s_0 的分布向量为 P_0 ,确定 k 步后的状态概率分布:

$$P(k) = P_0 P^k \quad (6)$$

1.3 加权马尔可夫链

加权马尔可夫链利用初始数据包含的信息,在马尔可夫链的步数权重上进行改进,考虑到不同步长转移矩阵对预测结果的影响。

加权马尔可夫链具体方法如下:

- 1)建立分级标准;
- 2)依据分极标准,确定与每个数据相对应的状态;
- 3)根据式(7)计算各阶自相关系数:

$$r_k = \frac{\sum_{i=1}^{n-k} (x_i - \bar{x})(x_{i+k} - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (7)$$

- 4)根据式(8)归一化不同阶的自相关系数:

$$\omega_k = \frac{|r_k|}{\sum |r_k|} \quad (8)$$

- 5)将上一步结果的统计信息用于获得不同步长马尔可夫链的转移概率矩阵;

- 6)将原始数据相对应的状态作为初始状态向量,并结合转移概率矩阵以预测状态概率;

- 7)将相同状态的每个预测概率的加权累积得到预测概率,并且选择概率最大的对应状态为该周期的预测状态。将预测状态转换为预测值,得到的结果加入原序列后,再重复步骤1)~步骤7)以执行下一轮预测。

加权马尔可夫链利用了马尔可夫链加权和来预测状态,将不同步长的自相关系数进行处理,极大地利用了数据所包含的信息。

1.4 分位数回归原理

分位数回归概念由Koenker等在1978年首次提出^[11],其利用最小化残差绝对值加权和估计模型参数^[12]。随机变量 Y 的所有性质均可以其分布函数 $F(y) = P(Y \leq y)$

来描述^[13], 这个随机变量的 τ 分位数函数的定义式为:

$$Q(\tau) = \inf\{y: F(y) \geq \tau\}, 0 < \tau < 1 \quad (9)$$

定义“检验函数”为:

$$\rho(u) = \tau u l(u \geq 0) + (\tau - 1)ul, u < 0 \quad (10)$$

式中, $l(u)$ —— 指示函数, $u \geq 0$ 时, $l(u) = 0$; $u < 0$ 时, $l(u) = 1$ 。

一般的线性条件分位数函数为: $Q(\tau|x) = x'\beta(\tau)$ 。对于随机变量 Y 的一个随机样本 $\{y_1, y_2, \dots, y_n\}$ 通常 τ 分位数的样本分位数线性回归要求满足:

$$\min_{\beta \in R} \rho_{\tau}(y_i - \beta_{\tau} X_i) \quad (11)$$

对于任意的 $0 < \tau < 1$ 通过求解式(12), 得到参数估计值。

$$\hat{\beta} = \arg \min_{\beta} \sum_i \rho_{\tau}(y_i - \beta_{\tau} X_i) \quad (12)$$

由于预测功率与各种不确定性因素紧密相关, 分位数函数可描述为:

$$Q(\tau) = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + \varepsilon \quad (13)$$

式中, β_i —— 参数向量; X_i —— 输入向量, 本文输入量为风速与前一时刻功率值, 输出量为功率; n —— 输入维度; ε —— 设定的残差。

在现有文献中^[14]分位数回归方法主要有秩得分法, 直接估计法以及重复抽样法。本文利用重复抽样方法, 求解过程如 2.3 节所示, 在克服直接估计方法和秩得分方法缺点的前提下, 不仅降低了运算所用时间, 而且还能进行大量的数据运算。

2 基于经验模式分解与马尔可夫链的 QR 风功率区间预测模型

2.1 风速的预测

风速是非线性的可变时间序列, 按照初始风速时间序列, 利用 EMD 方法自适应地分解为一系列不同的 IMF, 然后不同的 IMF 分别进行马尔可夫链预测风速。最后, 将所有预测值累加以给出最终的风速预测值。

具体的预测步骤如下:

- 1) 使用经验模式分解方法分解原始序列以获得不同 IMF 分量;
- 2) 不同分量均进行马尔可夫链模式预测风速;
- 3) 累积步骤 2) 的预测值以获得最终风速预测值。

2.1.1 对历史风速进行经验模式分解

经过经验模式分解后的分量更加平稳, 进而提高预测精度。利用经验模式分解方法对原始风速序列进行分解结果如图 1 所示。

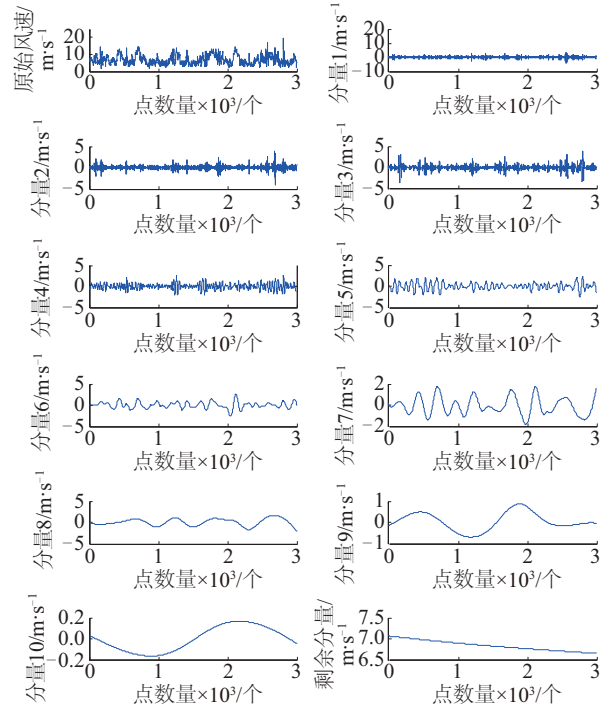


图1 原始风速进行经验模式分解

Fig. 1 Original wind speed is decomposed by EMD

2.1.2 对不同频率风速进行马尔可夫链预测

在 2.1.1 节中获得不同频段的风速, 利用绝对分布马尔可夫链方法, 即采用步长为 1 的马尔可夫链模型和初始状态向量来预测未来时刻的预测值。为了获得更好的预测效果, 利用加权马尔可夫链方法分别得到 1~6 步长的绝对分布, 并根据式(7)和式(8)获得最终的预测风速值。结合风电输出特性, 具体方法步骤为:

- 1) 建立模型, 对数据进行归一化处理;
- 2) 根据风速分布, 将处理后的数据分为 24 种状态序列;
- 3) 根据状态序列计算 1~6 步不同步长下的转移频率矩阵和对应的转移概率矩阵;
- 4) 将与前几节中的风速值相对应的状态作为初始状态向量, 并根据式(6)结合转移概率矩阵以预测状态概率;
- 5) 将相同状态的每个预测概率的加权累积得到预测概率, 并且选择概率最大的对应状态即为该周期的预测状态。将风速预测状态转换为风速预测值, 得到结果加入原序列后, 再重复步骤 1)~步骤 5), 可执行下一轮预测, 图 2 显示该流程步骤。

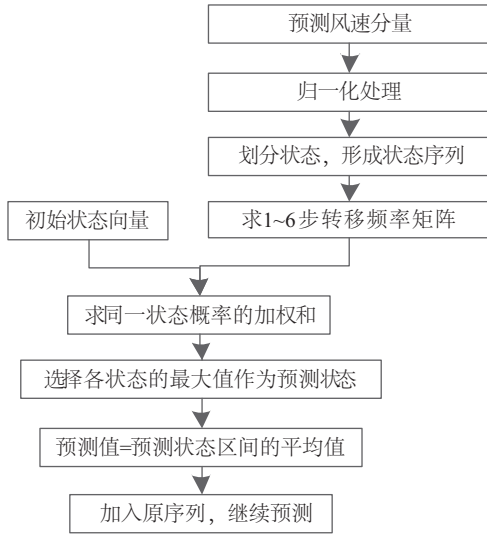


图2 加权马尔可夫链模型流程图

Fig. 2 Flow chart of weighted Markov chain model

2.2 基于分位数回归的风功率概率置信区间预测

以输入变量为预测风速与前一时刻功率,输出变量为实际功率,置信度为 $1-\alpha$ 为例,由于预测模型参数变量不多,分位数回归的线性规划任意基本解如式(14)所示,得到初始参数估计值:

$$\beta = X(h)^{-1}y(h) \quad (14)$$

接下来求解残差,将初始参数估计值代入式(13)中可得 3000 个残差,对残差进行重复抽样,求取在不同残差下满足 $\min_{\beta \in R} \rho_{\tau}(y_i + \varepsilon - \beta, X_i)$ 的 β 值,将其按照升序排列:

$$\beta_1^* \leq \beta_2^* \leq \beta_3^* \leq \dots \leq \beta_n^* \quad (15)$$

求近似分位点 $\beta_{\frac{\alpha}{2}}^*$ 、 $\beta_{1-\frac{\alpha}{2}}^*$ 及对应的残差 ε_1 、 ε_2 分别作为分位数函数上下限所对应的最终参数估计值与最终残差值,即置信度为 $1-\alpha$ 的近似区间可描述为:

$$\left[\beta_{\frac{\alpha}{2}}^* X_i + \varepsilon_1, \beta_{1-\frac{\alpha}{2}}^* X_i + \varepsilon_2 \right] \quad (16)$$

2.3 风功率概率区间预测步骤

采用经验模式分解和加权马尔可夫链的分位数回归法进行概率性区间预测的具体步骤如下:

- 1) 将历史数据进行必要的剔除坏点等预处理,再将历史风速进行经验模式分解得到不同频率段的风速;
- 2) 根据不同的频率段分别建立马尔可夫链模型,得到 1~6 步的转移矩阵,6 步加权得到最终风速预测值;
- 3) 按照预测风速的数量确定抽样次数,采用重复抽样法分位数回归计算 B 个样本在某置信水平下的参数估计值与残差;
- 4) 代入式(13),确定不同的分位数函数,转化为预

测值的置信区间上下限;

5) 将每个时刻的预测值的置信区间上限和下限分别联结即可形成上下 2 条包络线,得到概率性区间预测,总流程图如图 3 所示。

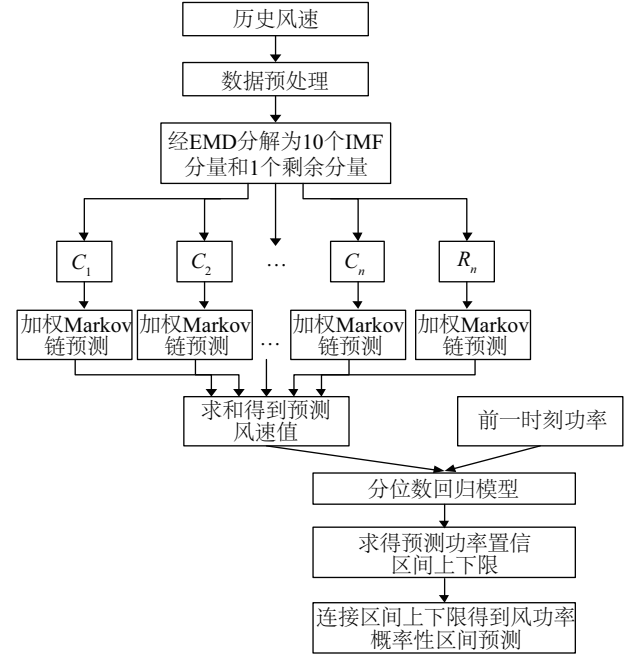


图3 经验模式分解与加权马尔可夫链的QR法风电功率概率性区间预测流程图

Fig. 3 Flow chart of wind power probability interval prediction for EMD, weighted Markov chain and QR method

3 算例分析

以西北某风场为例,该风场总装机容量为 199.5 MW,时间分辨率为 15 min,取风场 2014 年 9 月 1 日~10 月 15 日期间从现场采集到的风电功率数据,仿真验证本文方法的可行性,与马尔可夫链下的 QR 法、加权马尔可夫链的 QR 法的预测结果作对比,验证本方法的优越性。

3.1 预测风速的求取

统计 9 月 1 日~10 月 15 日的历史风速数据,4320 个点,去除重复点及明显异常点(负值点),剩余有效点数量为 3000 个,功率与风速显著相关,首先将历史风速进行经验模式分解,再分别建立加权马尔可夫链模型,相加得到最终的预测风速。

3.2 预测功率上下限的求取

以 80% 的置信度为例,输入量为预测风速与前一时刻的功率,进行重复抽样(次数 $B=2000$),计算 80% 置信区间下的各参数估计值与残差,代入式(16)即可得到预测功率的上下限。

3.3 仿真结果与分析

采用经验模式分解与加权马尔可夫链下 QR 法对 9 月 1 日~10 月 15 日的实际风功率、历史风速样本数据进行统计分析获取各功率段置信区间的上下限。然后对 10 月 15 日后的 400 个点进行概率性预测,获取满足风功率分布规律的置信区间。在实际应用中,电力系统总是需要较高的置信水平才能获得更准确的信息,从而保证系统的安全。因此,置信水平选择 80%、85% 和 90%。

使用 Matlab 程序来获得不同置信水平的预测区 (PI)。该算法的详细测试结果,包括 PI 评估指标区间覆盖率 (PI coverage probability, $PICP$)、区间平均带宽 (PI normalized average width, $PINAW$),见表 1。

$$PICP = \frac{1}{N_t} \sum_{i=1}^{N_t} k_i^{(a)} \quad (18)$$

$$PINAW = \frac{1}{N_t} \sum_{i=1}^{N_t} [U_i^{(a)}(x_i) - L_i^{(a)}(x_i)] \quad (19)$$

式中, N_t ——预测样本数量; $k_i^{(a)}$ ——布尔量,若预测目标值落入预测区间,值为 1,否则为 0; $U_i^{(a)}$ ——设定置信度下对应预测区间上限; $L_i^{(a)}$ ——设定置信度下对应预测区间下限。

表 1 PI 评估指标

Table 1 PI evaluation index

置信度/%	$PICP$ /%	$PINAW$
90	89.0	335.0
85	85.9	291.8
80	81.0	258.0

图 4 为 90%、85% 和 80% 置信概率下的风电功率区间预测曲线。可看出,构建的模型可有效跟踪风力时间序列的变化。该模型可包围置信水平附近的实际值,实际值(落在外部)与 PI 边界之间的偏差相对较小。






图 4 90%、85%、80% 置信水平下的预测区间

Fig. 4 Prediction intervals under 90%, 85% and 80% confidence level

3.4 对比验证

选取同样的训练样本和测试样本,为了对比提出方法的有效性分别采用马尔可夫链的 QR 法和加权马尔可夫链下的 QR 法进行风电功率预测区间的估计。以 $PICP$ 和 $PINAW$ 为区间质量评估指标, MQ 代表马尔可夫链下的 QR 法, GMQ 代表加权马尔可夫链下的 QR 法, EGMQ 代表本文提出的经验模式分解与加权马尔可夫链下的 QR 法。3 种算法在不同置信度下的 $PICP$ 、 $PINAW$ 指标值如表 2 所示。

$PICP$ 一定时, $PINAW$ 值越小,表明对应区间范围越窄,预测精度越高。从表 2 可看出, EGMQ 法能提供令人满意的 PI 性能,它能反映对实际功率值的覆盖率,表明 PI 的高可靠性。在 $PICP = 80\%$ 、 85% 、 90% 的置信水平下,所提出的方法和 GMQ、MQ 几乎产生相同的 $PICP$,而所提出的 EGMQ 具有较小的 $PINAW$,区间平均带宽越小意味着预测精度越高,不确定性程度越小。综合对比之下,经验模式分解与加权马尔可夫链下的 QR 法能得到更优良的预测效果。

表2 不同算法下性能指标比较

Table 2 Performance index comparison of different algorithms

置信度/%	算法	PICP/%	PINAW
80	MQ	80.00	294.90
	GMQ	81.00	285.88
	EGMQ	81.05	258.07
85	MQ	85.80	349.00
	GMQ	86.00	302.00
	EGMQ	86.00	291.81
90	MQ	90.00	416.00
	GMQ	91.00	404.00
	EGMQ	91.00	335.00

4 结 论

本文提出的基于经验模式分解与加权马尔可夫链下QR法的风电功率概率区间预测法有以下特点：

1)不必假定预测功率的误差分布,就能获得在任何置信度下不同预测功率的波动范围。

2)使用经验模式分解方法将原始风速按照时间序列自适应地分解为一系列IMF分量,使得原始序列平稳化,从而提高功率的预测精度。

3)使用加权马尔可夫链模型,执行不同IMF建模预测,以反映每个步骤的转移概率矩阵与预测效果之间的关系,探究了初始数据具有的尽可能多的信息。

4)通过分位数回归方法建立最终的功率区间预测模型,并通过将区间覆盖率度量与区间的平均带宽进行比较来评估区间的准确性。最后通过比较显示了该方法良好的区间预测效果。

[参考文献]

- [1] MILLER N W, GURU D, CLARK K. Wind generation [J]. IEEE industry applications magazine, 2009, 15 (2): 54-61.
- [2] LANDBERG L. Short-term prediction of the power production from wind farm [J]. Journal of wind engineering and industrial aerodynamics, 1999, 80 (1): 207-210.
- [3] KHOSRAVI A, NAHAVANDI S. Combined nonparametric prediction intervals for wind power generation [J]. IEEE transactions on sustainable energy, 2013, 4(4): 849-856.
- [4] HUANG N E, SHEN Z, LONG S, 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: 903-995.
- [5] ZHU Z H, SUN Y L, JI Y. Short-term load forecasting based on empirical mode decomposition and least square support vector machine [J]. Relay, 2007, 35 (8): 38-40.
- [6] 刘兴杰, 米增强, 杨奇逊, 等. 一种基于EMD的短期风速多步预测方法 [J]. 电工技术学报, 2010, 25(4): 165-170.
- LIU X J, MI Z Q, YANG Q X, et al. A short-term wind speed multi-step prediction method based on EMD [J]. Journal of electrical engineering, 2010, 25(4): 165-170.
- [7] 周封, 金丽斯, 王丙全, 等. 基于高阶 Markov 链模型的风电功率预测性能分析 [J]. 电力系统保护与控制, 2012, 4(6): 6-10.
- ZHOU F, JIN L S, WANG B Q, et al. Analysis of the wind power forecasting performance based on high-order Markov chain models [J]. Power system protection and control, 2012, 4(6): 6-10.
- [8] 吴文可, 文福拴, 薛禹胜, 等. 基于马尔可夫链的电力系统连锁故障预测 [J]. 电力系统自动化, 2013, 37 (5): 29-37.
- WU W K, WEN F S, XUE Y S, et al. Fault diagnosis of power system based on Markov chain [J]. Power system automation, 2013, 37(5): 29-37.
- [9] 文习山, 蓝磊, 蒋日坤. 采用 Markov 模型的输电线路及绝缘子运行风险评估 [J]. 高电压技术, 2011, 37 (8): 1952-1960.
- WEN X S, LAN L, JIANG R K. Markov model for transmission lines and insulator operation risk assessment [J]. High voltage technology, 2011, 37 (8): 1952-1960.
- [10] 党小超, 郝占军, 王筱娟. 模糊加权 Markov 链的用户行为预测 [J]. 兰州大学学报(自然科学版), 2011, 47 (1): 109-114.
- DANG X C, HAO Z J, WANG X J. Fuzzy behavior prediction of fuzzy weighted Markov chains [J]. Journal of Lanzhou University (natural science edition), 2011, 47(1): 109-114.
- [11] 李智, 韩学山, 杨明, 等. 基于分位点回归的风电功率波动区间分析 [J]. 电力系统自动化, 2011, 35(3): 83-87.
- LI Z, HAN X S, YANG M, et al. Analysis of wind power fluctuation interval based on quantile regression [J]. Automation of electric power systems, 2011, 35

- (3): 83-87.
- [12] 李雨芹, 陈守东. 分位数回归与风险度量及其应用 [D]. 长春: 吉林大学, 2009.
- LI Y Q, CHEN S D. Quantile regression and its application in risk measurement [D]. Changchun: Jilin University, 2009.
- [13] 刘永前, 韩爽, 胡永生. 风电场出力短期预报研究综述[J]. 现代电力, 2007, 4(5): 6-11.
- LIU Y Q, HAN S, HU Y S. Review on short-term wind power prediction [J]. Modern electric, 2007, 4(5): 6-11.
- [14] 陈建宝, 丁军军. 分位数回归技术综述[J]. 统计与信息论坛, 2008, 23(3): 89-96.
- CHEN J B, DING J J. A review of technologies on quantile regression [J]. Statistic & information forum, 2008, 23(3): 89-96.

PROBABILISTIC INTERVALS FORECASTING OF WIND POWER BASED ON EMD WEIGHTED MARKOV CHAIN QR METHOD

Yang Xiyun¹, Ma Xue¹, Zhang Yang¹, Zhang Huang¹, Geng Na²

(1. School of Control and Computer Engineering, North China Electric Power University, Beijing 102206, China;

2. Jilin Electric Power Research Institute, Changchun 130021, China)

Abstract: The study of uncertainties in wind power is critical to power system planning and operational decision making. A method of wind power probability interval prediction based on empirical mode decomposition (EMD), weighted Markov chain and quantile regression (QR) is proposed. Because the wind power data is significantly related to the wind speed, the empirical mode decomposition method is applied to historical wind speed. Then the wind speed of different frequency segments is obtained. We take the wind speed of different frequency segments as a sample, and the weighted Markov chain prediction is carried out respectively. Add the results to get the final predicted wind speed. Finally, the predicted wind speed is applied to the QR prediction model to obtain the upper and lower limits of the wind power probability interval at a certain confidence level. The interval coverage and interval average bandwidth were used as evaluation indexes. Compared with the QR method under the Markov chain and the QR method under the weighted Markov chain, it is shown that the proposed QR method based on the EMD and the weighted Markov chain has the higher prediction interval coverage, the narrower average bandwidth, and the better accuracy.

Keywords: wind power; interval prediction; EMD; weighted Markov chain; QR