

DOI: 10.7667/PSPC160284

基于改进 EEMD-SE-ARMA 的超短期风功率组合预测模型

田波, 朴在林, 郭丹, 王慧

(沈阳农业大学信息与电气工程学院, 辽宁 沈阳 110866)

摘要: 针对风力发电功率时间序列具有非线性和非平稳性的特性, 提出了一种改进的集成经验模态分解(Modified Ensemble Empirical Mode Decomposition, MEEMD)-样本熵(Sample Entropy, SE)-ARMA 的风电功率超短期组合预测模型。将 EEMD 分解中添加的白噪声信号改为添加绝对值相等的正负两组白噪声信号, 并将 MEEMD 分解过程中的 EMD 步骤使用端点延拓和分段三次埃尔米特插值进行改进, 形成一种改进的 EEMD 分解算法(即 MEEMD)。利用 MEEMD-SE 将风力发电功率时间序列分解为一系列复杂度差异明显的风电子序列; 针对每一个不同的子序列建立适当的 ARMA 预测模型; 将各预测分量进行叠加重构, 得到最终的风电功率预测值。通过算例分析及与其他几种预测模型预测结果的对比, 证明 MEEMD-SE-ARMA 组合预测模型可以有效地提高风力发电功率超短期预测的精度。

关键词: 改进的集成经验模态分解; 风电预测; 样本熵; 时间序列; 组合预测模型; 端点延拓

Wind power ultra short-term model based on improved EEMD-SE-ARMA

TIAN Bo, PIAO Zailin, GUO Dan, WANG Hui

(College of Information and Electrical Engineering, Shenyang Agricultural University, Shenyang 110866, China)

Abstract: In view of the nonlinear and non-stationary characteristics of wind power time series, this paper presents a modified ensemble empirical mode decomposition (MEEMD)-sample entropy (SE)-ARMA wind power ultra short term combined forecasting model. The white noise signal added in the EEMD decomposition is changed to two groups positive and negative white noise signal which have the equal absolute value, and the EMD steps of the decomposition process of MEEMD is improved with the endpoint extension and three piecewise Hermite interpolation, forming a modified EEMD decomposition algorithm (MEEMD). The wind power time series is decomposed into a series of complex wind power generation by MEEMD-SE, and the ARMA forecasting model is built for each different sub sequence, and the final wind power forecast value is obtained. Through numerical analysis and comparison with other forecasting models, the results show that the MEEMD-SE-ARMA combination forecasting model can effectively improve the accuracy of the ultra short term forecasting of wind power generation.

This work is supported by National Science & Technology Pillar Program during the 12th Five-year Plan Period (No. 2012BAJ26B00).

Key words: improved ensemble empirical mode decomposition; wind power prediction; sample entropy; time series; combined prediction model; endpoint extension

0 引言

在可再生能源的研究领域中, 风力发电因为技术应用发展较为成熟受到了越来越多国家的重视^[1]。因为风力发电固有的间歇性和波动性, 使电网的安全运行和调控都承受着巨大的挑战。为了降低风电并网后对电网的影响, 对风电功率进行准确

的超短期预测十分重要^[2]。准确的预测可以降低运营成本和旋转备用容量^[3], 提高能源利用率, 为相关部门进行电网调度及制定运行方案提供科学可靠的支持^[4]。

目前, 风电功率预测的方法主要有人工神经网络法、时间序列法、卡尔曼滤波法、模糊算法、组合方法等。文献[5]中采用了广义自回归条件异方差(GARCH)预测模型, 该模型建立简单但是仅适用于高频率序列, 并且随着预测步长增加精度会降低, 无

法提取风电功率的局部波动特征。文献[6]中采用了时间序列模型与 RBF 神经网络组合预测模型,但是时间序列不能很好地表现风电功率变化的趋势,并且 RBF 神经网络算法收敛速度慢容易陷入局部最优。文献[7]中提出了经验模式分解(EMD)和支持向量机的组合预测模型,但是 EMD 分解方法本身存在着模态混叠现象,分解形成固有模态函数时会发生提取信息特征混淆的现象。文献[8]中提出了集成经验模式分解(EEMD)方法和高斯过程回归(GA-GPR)组合的预测模型,虽然 EEMD 在很大程度上改善了 EMD 分解中模态混叠的现象,但是 EEMD 中添加的白噪声如果幅值过低无法抑制混叠现象,幅值过高又会增大计算量且会出现较多的伪分量。

本文提出一种 MEEMD 分解算法,不仅可以改善 EEMD 分解中计算量过大和添加白噪声幅值不当的问题,还能改善 EEMD 分解过程 EMD 步骤中端点效应失真的情况,并将 MEEMD 分解法与样本熵和 ARMA 预测模型进行组合,应用于风电功率超短期预测中,结果证明 MEEMD-SE-ARMA 组合预测模型可以有效地提高风力发电功率超短期预测的精度。

1 算法原理

1.1 EMD

经验模式分解(Empirical Mode Decomposition, EMD)是 1998 年美国华裔科学家 Huang 提出的一种处理非平稳非线性信号的方法^[9],相对于传统的小波分析信号处理方法,该方法不需要设定基函数,具有自适应性。在对原始信号进行处理中,会得到有限个基本模式分量(IMF),虽然得到的 IMF 分量中会有不同程度的非平稳性,但这种相互影响作用会被隔离从而降低非平稳性对预测的影响。其中 IMF 要满足两个条件:(1)在整个数据序列中,穿越极值点与零点的数量必须相等或最多相差一个;(2)在信号上任意一点,局部极大值和局部极小值的平均值为零。EMD 具体操作步骤如下:

1) 计算原始信号的极值点,然后用三次样条函数根据极大极小值点拟合出上、下包络线。

2) 计算上、下包络线的平均值,并求出原始信号与包络线均值之间的差值,如果差值满足 IMF 条件,则为原始信号的第一个 IMF 分量。

3) 如果不满足 IMF 条件,则将差值作为原始信号重复 1)、2)步骤,直到满足 IMF 的条件。

4) 将第一个 IMF 分量从原始信号中分离出来,使分离后的剩余部分作为原始信号重复 1)~3)步骤,得出第二个 IMF 分量,以此类推,直到成为单调函

数满足终止条件,这样就得到 n 个 IMF 分量和 1 个残余分量 res。

当原始信号的时间尺度存在跳跃性变化时,会出现模态混叠现象,即一个 IMF 分量中包含不同时间尺度特征成分,这种现象会影响预测模型对每个 IMF 分量的自适应性,最终影响预测精度。

1.2 改进的 EMD

在 EMD 分解方法求包络线的过程中,使用的是三次样条插值算法。该算法的计算原理是用连续的曲线逼近求解,当相邻的极大值或极小值间的曲线不单调时,会导致求解包络线出现欠冲或者过冲的现象。为了解决求解包络线时出现的问题,本文应用了文献[10]中提出的分段三次埃尔米特插值法。该方法能够在计算过程中保证非平稳信号相邻极大值或极小值间曲线的单调性,从而降低求解过程中出现的欠冲或过冲现象,使得求得的包络线更精确,具体计算原理参考文献[10]。

目前对端点延拓的方法有镜像延拓、极值平均延拓、极值延拓、平行延拓、多项式拟合和边界局部特征尺度延拓。本文通过 Matlab 仿真实验,使用的仿真信号采样频率为 500 Hz,通过对比相似系数与相对误差的值选用最优的端点延拓,并对 EMD 分解算法进行进一步改进。

1) 计算 EMD 分解后各分量信号与对应的原信号之间的相似系数,评价各端点效应的抑制效果。

$$\rho_i(x_i(t), IMF_i(t)) = \frac{\text{cov}(x_i(t), IMF_i(t))}{\sqrt{\sigma^2(x_i)}\sqrt{\sigma^2(IMF_i)}} \quad (1)$$

式中: $x_i(t)$ 表示对应的原始信号组成分量; $IMF_i(t)$ 表示信号经过 EMD 分解后的第 i 个模态分量; cov 表示协方差; σ^2 表示方差。

2) 计算 EMD 分解后得到的各个 IMF 分量和原始信号相应的分量之间的平均相对误差。

$$\text{error}IMF_i = \frac{\text{sqrt}\left(\sum_{k=1}^N [x_i(k) - IMF_i(k)]^2\right)}{N} \quad (2)$$

式中: $x_i(t)$ 表示对应的原始信号第 i 个分量; $IMF_i(t)$ 表示信号经过 EMD 分解后的第 i 个模态分量; N 表示信号的总个数。

各端点延拓仿真对比结果如表 1 所示。在表 1 中,相似系数越高,相对误差越小,说明端点延拓效果越好。对比几种端点延拓算法的结果可以得出极值延拓的误差最小,相似程度最高。因此改进的 EMD 算法首先使用极值延拓进行改进,将信号的左右两端分别延拓 N 个点,再使用分段三次埃尔米特插值算法进行包络线的求解。

表 1 各端点延拓算法仿真对比结果

端点延拓算法	相似系数	相对误差
原始不延拓 EMD	0.979 19	165.9844
极值平均延拓 EMD	0.630 26	172.4337
极值延拓 EMD	0.9975	166.9781
边界局部特征尺度延拓 EMD	0.4944	165.9617
镜像延拓 EMD	0.983 53	166.1758
平行延拓 EMD	0.280 75	365.2852
多项式拟合延拓 EMD	0.992 66	166.7136

1.3 EEMD

为了解决 EMD 算法中出现的模态混叠现象, 2005 年 Wu 和 Huang 等人提出了一种新型噪声辅助数据分析方法, 即集合经验模式分解^[11](Ensemble Empirical Mode Decomposition, EEMD)。其本质是将白噪声加入原信号中, 利用白噪声会自动分布到合适的参考尺寸上, 根据零均值噪声的特性, 经过多次平均后噪声将相互抵消, 集成均值的结果就可作为最终结果, 这样避免了尺度混合问题, 最终获得的 IMF 分量可以维持唯一性。EEMD 的操作步骤如下。

1) 向待分解信号中加入正态分布白噪声。

2) 将加入白噪声的待分解信号进行 EMD 分解, 获得多个 IMF 分量。

3) 重复 1)、2)步, 并且每次加入新的白噪声序列。

4) 将每次得到的 IMF 分量集成均值作为最终结果。

通过 EEMD 算法的步骤可以看出, 该算法依赖添加的白噪声幅度和集成次数, 当添加的白噪声幅度过低将无法抑制模态混叠现象, 而幅值过高会出现较多的伪分量, 并且每添加一次白噪声就要进行一次 EMD 分解, 计算量大大增加。

1.4 MEEMD

为了避免 EEMD 分解方法中出现的非必要集成平均, 文献[12]和文献[13]中提出了一种改进的集总平均经验模式分解(Modified Ensemble Empirical Mode Decomposition, MEEMD)方法。该方法能够解决 EEMD 方法中出现的计算量过大、添加白噪声引起的重构误差等缺点。本文在文献[12]、文献[13]提出的 MEEMD 方法基础上, 将 MEEMD 分解过程中出现的 EMD 方法均使用极值端点延拓和分段三次埃尔米特插值进行改进, 从而更好地消除了分解过程中产生的端点失真和模态混叠现象, 使得 IMF 分量更标准更有意义, 具体算法如下。

1) 参与辅助计算的白噪声信号的均方根值应接近于待分解信号的内部噪声, 或在保证抑制模态

混叠的情况下, 不高于待分解信号均方根的 0.3 倍。

2) 在原始信号 $x_{(t)}$ 中接入绝对值相等的正负两组白噪声信号 $wn_{+(t)}$ 和 $wn_{-(t)}$, 分别进行 EEMD 分解, 将 EEMD 分解过程中的 EMD 步骤使用本文提出的改进 EMD 进行分解。

$$x_{(t)} + wn_{\pm(t)} \xrightarrow{\text{EEMD}} \sum_{i=1}^m \left[\frac{\sum_{j=1}^n [d_{\pm i, j(t)}]}{n} \right] + \frac{\sum_{j=1}^n p_{\pm j(t)}}{n} \quad (3)$$

$$x_{(t)} + wn_{\pm(t)} = \sum_{i=1}^m [\overline{d_{\pm i(t)}}] + \overline{p_{\pm(t)}} \quad (4)$$

式中: $d_{i, j(t)}$ 表示第 j 次使用改进 EMD 分解得到的第 i 个 IMF 分量; $p_{j(t)}$ 表示 j 次改进 EMD 分解得到的残余分量; $\overline{d_{i(t)}}$ 表示最终 EEMD 得到的第 i 个 IMF 分量; $\overline{p_{(t)}}$ 表示最终 EEMD 分解得到的残余分量。

3) 平均得到的两组 IMF 分量以便极大地消除白噪声的残余。

$$d_{i(t)} = \frac{\overline{d_{+i(t)}} + \overline{d_{-i(t)}}}{2} \quad (5)$$

4) 对得到的 $d_{i(t)}$ 再次使用改进的 EMD 分解, 使得更好地消除模态分裂的问题。

$$d_{1(t)} \xrightarrow{\text{newEMD}} c_{1(t)} + q_{1(t)} \quad (6)$$

$$[q_{(k-1)(t)} + d_{k(t)}] \xrightarrow{\text{newEMD}} c_{k(t)} + q_{k(t)} \quad (7)$$

式中: $c_{1(t)}$ 表示 $d_{1(t)}$ 经过改进 EMD 分解得到的第一个标准 IMF 分量, 其中 $q_{1(t)}$ 表示残余; $c_{k(t)}$ 表示分解得到的第 k 个标准 IMF 分量, $q_{k(t)}$ 表示其分解后的残余, $k=1, 2, \dots, m$ 。则 MEEMD 最终可以表示为

$$x_{(t)} \xrightarrow{\text{MEEMD}} \sum_{k=1}^m [c_{k(t)}] + r_{(t)} \quad (8)$$

式中, $r_{(t)}$ 表示最终的残余分量。

1.5 样本熵

样本熵(Sample Entropy, SE)是 Richman 于 2000 年提出的一种改进的复杂性测试方法^[14-15], 它的计算原理与近似熵类似, 但改进了近似熵中统计量不一致的问题, 降低了近似熵的误差。样本熵不依赖数据长度, 具有更好的一致性并且对于丢失的数据不敏感, 具体算法参考文献[14]。

样本熵可以用 $\text{SampEn}(m, r, N)$ 表示, 其中 m 表示维数, r 表示相似容限(又叫阈值), N 表示长度。样本熵最终表达式如式(9)。

$$SampEn(m, r, N) = -\ln \left[\frac{B^{m+1}(r)}{B^m(r)} \right] \quad (9)$$

由上式可以看出 $SampEn$ 的值与 m 和 r 有关, 一般情况下 $m=1$ 或 2 , $r=0.1SD \sim 0.25SD$ (其中 SD 表示原始时间序列 x_t 的标准差), 本文中 $m=2$, $r=0.2SD$ 。

1.6 ARMA 预测模型

目前在风电场超短期风功率预测中, 时间序列法是应用较为广泛的一种主要方法, 它是由 Box 和 Jenkins 两位创立的用于处理随机事件序列的模型, 应用时间序列法进行预测较为简单, 只需要输入风电场的输出功率序列并使用适当的预测模型便可以输出预测值。时间序列模型可以分为三种, 分别是: AR(自回归)模型、MA(移动平均)模型和 ARMA(自回归移动平均)模型^[16], 式(10)为其基本结构。

$$\begin{cases} x_t = \varphi_0 + \varphi_1 x_{t-1} + \varphi_2 x_{t-2} + \dots + \varphi_p x_{t-p} + \\ \quad \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \\ \varphi_p \neq 0, \theta_q \neq 0 \\ E(\varepsilon_t) = 0, Var(\varepsilon_t) = \sigma_\varepsilon^2, E(\varepsilon_t \varepsilon_s) = 0, s \neq t \\ E(x_s \varepsilon_t) = 0, \forall s < t \end{cases} \quad (10)$$

式中: x_t 表示原始序列; p 表示自回归模型的阶数; q 表示移动回归模型的阶数; φ_i 与 θ_i 表示模型参数。由上式可以看出令 $q=0$ 时, ARMA(p, q)模型就退变成了 AR(p)模型; 同理 $p=0$ 时, ARMA(p, q)模型退变为 MA(q)模型。

1.7 GARCH 模型

广义自回归条件异方差模型(GARCH)在 1986 年由经济学家 Bollerslev 提出。GARCH 模型的实质就是应用残差平方序列的 q 阶移动平均值和序列的 p 阶自回归来拟合当前的异方差函数值。其结构如式(11)。

$$\begin{cases} x_t = f(t, x_{t-1}, x_{t-2}, \dots) + \varepsilon_t \\ h_t = \lambda_0 + \sum_{i=1}^p \eta_i h_{t-i} + \sum_{j=1}^q \lambda_j \varepsilon_{t-j}^2 \\ \varepsilon_t = \sqrt{h_t} e_t \end{cases} \quad (11)$$

式中: $\lambda_j > 0$, $\eta_i > 0$; $f(t, x_{t-1}, x_{t-2}, \dots)$ 为序列 $\{x_t\}$ 的自回归模型; $\{\varepsilon_t\}$ 为残差序列; $\{e_t\}$ 为独立同标准正态分布的序列; h_t 为残差序列在 t 时刻的条件方差。

2 算例分析

为了验证基于 MEEMD-SE-ARMA 的风电功率预测组合模型的有效性, 本文利用了 Matlab 2014a 进行了编程, 建立了 MEEMD-SE 的数据序列处理模型, 使用 Eviews8 建立了 ARMA 预测模型最终建立了组合预测模型。本文中采用的数据是内蒙古赤

峰市某大型风场在 2015 年 1 月 1 日 00 时 00 分到 2015 年 1 月 3 日 23 时 45 分, 间隔为 15 min 的 288 个数据采样点。用 288 个实际风电功率进行分析, 使用 2015 年 1 月 4 日 00 时 00 分到 2015 年 1 月 4 日 03 时 45 分的间隔为 15 min 的 16 个风电功率进行测试验证, 原始风电功率时间序列如图 1 所示。

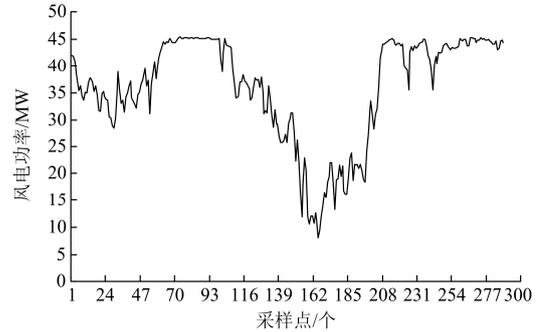


图 1 风电功率时间序列

Fig. 1 Wind power time series

由图 1 可知, 原始的风电功率具有明显的非线性, 原序列的单位根检验如表 2。根据表 2 可知, 原序列又具有非平稳性。本文应用 MEEMD 方法对原始风电时间序列进行分解处理, 得到一系列不同尺度的模式分量 IMF 和剩余分量 res 如图 2 所示。

表 2 单位根检验

Table 2 Unit root test

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.780 161	0.3900
Test critical values:		
1% level	-3.452 991	
5% level	-2.871 402	
10% level	-2.572 097	

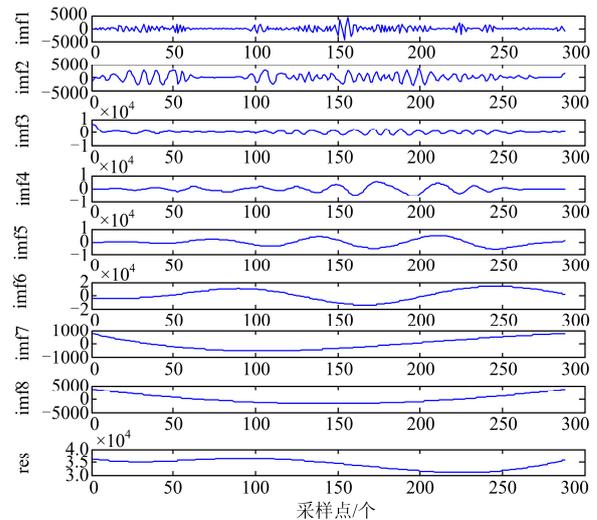


图 2 经 MEEMD 处理后的风电子序列

Fig. 2 Wind power sub-sequences processed by MEEMD

由图 2 可知, MEEMD 方法将非平稳非线性的原始风电功率时间序列分解成了 8 个较为平稳的 IMF 分量和一个剩余分量 res。由于分解后的 IMF 分量过多, 如果针对每一个 IMF 分量使用 ARMA 模型, 并分别进行拉格朗日乘子检验(LM), 检验是否满足建立自回归条件异方差(ARCH)预测模型的条件, 将会增大计算规模。为了减少对风电功率预测的计算量, 本文应用复杂系统理论的样本熵理论, 对分解后的 9 个 IMF 分量进行复杂度的评估, 各 IMF 分量的样本熵处理结果如图 3 所示。

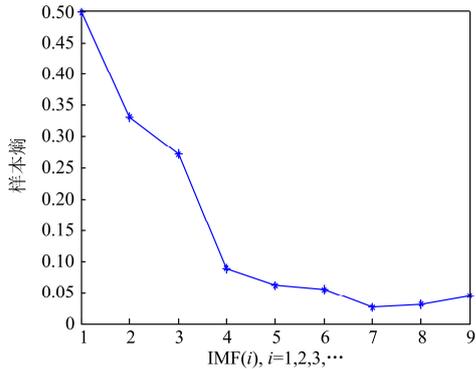


图 3 各 IMF 分量的样本熵
Fig. 3 Sample entropy of each IMF component

由图 3 可以看出, 整体 IMF 分量的样本熵呈现递减趋势, 随着 IMF 分量的频率降低, 其复杂程度也逐渐减少, 说明样本熵理论有效。因为部分相邻的 IMF 分量的样本熵的值相差不多, 可以将其进行叠加处理。根据图 3 可以看出, IMF4、IMF5 和 IMF6 分量可以进行叠加当作一个新的 IMF 分量, 同理 IMF7、IMF8 和 res 3 个分量也可以看成一个新的 IMF 分量, 最终得到 5 个新 IMF 分量序列, 合并后的新子序列结果如表 3 所示, 合并后的新子序列如图 4 所示。

表 3 各 IMF 分量合并后的新子序列

新序列号	1	2	3	4	5
原 IMF 分量序列号	1	2	3	4,5,6	7,8,9

根据 MEEMD-SE 处理后得到的新 IMF 分量, 使用时间序列的 ARMA 理论对每个 IMF 分量分别建立适应的预测模型, 首先对 IMF1 进行 ARMA 预测模型的建立。

IMF1 的单位根检验如表 4 所示。根据表 4 可以看出, 其 ADF 统计值为 -18.878 50, 小于 10% 水平下的临界值 -2.572 135, 且其 P 值为 0.0000, 这表明, 在 5% 显著水平下, 拒绝实际功率时间序列存在单位根假设, 可以认为实际功率为平稳的时间序列, 因此满足建立 ARMA 模型的前提。

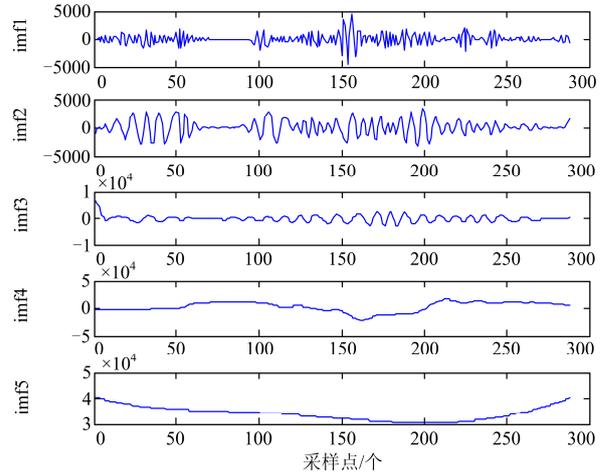


图 4 MEEMD-SE 处理后的风电子序列
Fig. 4 Wind power subsequences processed by MEEMD-SE

表 4 单位根检验

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-18.878 50	0.0000
Test critical values:		
1% level	-3.453 153	
5% level	-2.871 474	
10% level	-2.572 135	

自相关图如图 5 所示, 根据图 5 可以初步得出适合的模型阶数为 ARMA(3, 2), 通过对比 R²、DW 统计量、AIC 和 SIC 准则等数值, 进一步确定 IMF1 的预测模型阶数为 ARMA(3,2)。

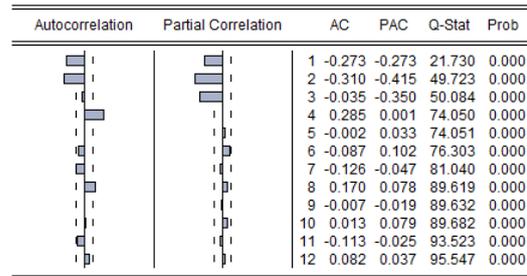


图 5 IMF1 的相关性检验

Fig. 5 Correlation test of IMF1

LM(拉格朗日乘子)检验是检验序列是否存在 ARCH 效应, 如果存在低阶的 ARCH 效应则建立 ARCH 模型, 若存在高阶的 ARCH 效应则建立相应的 GARCH 模型。对 ARMA(3,2)的残差进行 ARCH-LM 检验, 结果如表 5 所示。

根据表 5 可以看出 ARMA(3,2)的 LM 检验值为 8.450 782, 其概率均大于 5% 显著水平, 所以 ARMA(3,2)的 ARCH 效应是不显著的, 因此对 IMF1 只需建立 ARMA(3,2)模型。

表 5 ARCH-LM效应检验

Table 5 Test of ARCH-LM effect

项目	数值	概率
F	1.035 153	0.4097
R ²	8.450 782	0.3907

IMF2、IMF4 和 IMF5 的 ARMA 模型建立步骤同 IMF1, 此处不做赘述。ARMA 预测模型建立结果为 IMF1 为 ARMA(3,2), IMF2 为 ARMA(4,1), IMF4 为 ARMA(4,0), IMF5 为 ARMA(1,0)。

在 IMF3 的 ARMA 模型建立中, 根据单位根和自相关图已经确立了 ARMA(3,2)模型, 但是其 ARCH-LM 检验结果如表 6 所示。

表 6 ARCH-LM效应检验

Table 6 Test of ARCH-LM effect

项目	数值	概率
F	1.892 722	0.0012
R ²	15.080 99	0.0076

根据表 6 可以看出 ARMA(3,2)的 LM 检验值为 15.080 99, 其概率均小于 5%显著水平, 完全可以拒绝原假设, 所以 ARMA(3,2)的 ARCH 效应是显著的, 进一步分析确定 ARCH(q)模型, 其分析结果见表 7 所示。

表 7 LM 检验结果

Table 7 Result of LM test

参数	$q=1$	$q=2$	$q=3$	$q=4$
LM 检验值	15.080 99	15.089 72	15.394 82	15.739 41
相伴概率	0.0076	0.0078	0.0082	0.0089
参数	$q=5$	$q=6$	$q=7$	$q=8$
LM 检验值	15.392 83	16.473 62	16.928 37	17.892 73
相伴概率	0.0086	0.0091	0.0096	0.0102

从表 7 可以看出, ARCH 效应从 1 阶到 8 阶的 LM 检验的相伴概率均小于 5%, ARCH 效应是显著的, 因为 ARCH 效应的滞后阶数较大, 建立高阶的 GARCH(1,1)模型来提高预测精度, 所以对 IMF3 建立 ARMA(3,2)-GARCH(1,1)模型。

最后将各 IMF 分量预测模型得出的预测值叠加, 就可以得到风电功率的预测值, 具体步骤及使用预测模型如图 6 所示。

本文使用 2015 年 1 月 1 日 00 时 00 分到 2015 年 1 月 3 日 23 时 45 分间隔为 15 min 的 288 个实际风电功率为训练数据, 对 2015 年 1 月 4 日 00 时 00 分到 2015 年 1 月 4 日 03 时 45 分间隔为 15 min 的 16 个风电功率进行测试验证。

为了验证 MEEMD-SE-ARMA 组合预测模型对提高风电功率预测精度的有效性, 在同样的计算环境下分别使用 ARIMA 预测模型、EMD-SE-ARMA 组合预测模型及 EEMD-SE-ARMA 组合预测模型对相同的风电功率时间序列进行预测, 并对比分析 4 个预测模型得到的预测值, 实际值和各模型的预测值对比如图 7 所示。

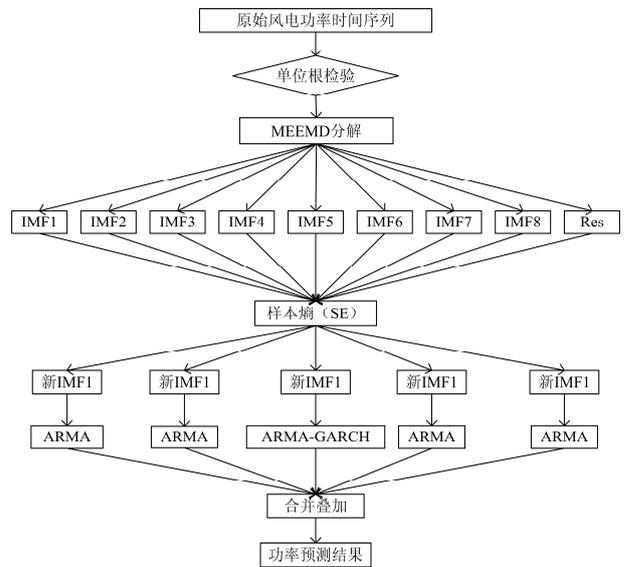


图 6 MEEMD-SE-ARMA 预测流程

Fig. 6 Prediction flowchart based on MEEMD-SE-ARMA

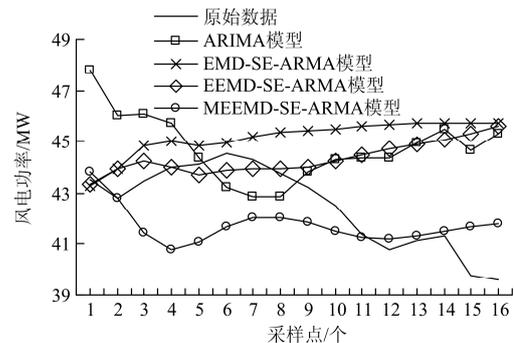


图 7 风电功率实际值及 3 种模型的 4 h 预测值

Fig. 7 Actual value of wind power and prediction results 4 h of three prediction models

为了评判各预测模型的精确性, 本文采用平均绝对百分误差 (Mean Absolute Percentage Error, MAPE) 作为衡量预测精度的标准, 其公式为

$$E_{\text{MAPE}} = \frac{1}{N} \sum_{i=1}^N \frac{|x - x'|}{x} \quad (12)$$

式中: x 为风电功率实际值; x' 为风电功率预测值; N 为预测数据的个数。

3 个预测模型的预测误差对比如表 8 所示。

表 8 各预测模型的预测误差比较

Table 8 Errors of each prediction model

方法名称	平均绝对百分误差(%)
ARIMA-GARCH 预测模型	6.47
EMD-SE-ARMA 预测模型	5.48
EEMD-SE-ARMA 预测模型	4.94
MEEMD-SE-ARMA 预测模型	3.35

根据图 7 和表 8 可以得知, 使用 MEEMD-SE-ARMA 组合预测模型作的 4 h 风电功率预测值与实际值最接近, 其 MAPE 仅为 3.35%, MEEMD-SE-ARMA 组合风电功率预测模型比 EMD-SE-ARMA 组合预测模型及 EEMD-SE-ARMA 组合预测模型的预测精度更为精确, 说明本文提出的对 EMD 分解及 EEMD 分解的改进方法是有效的。并且 3 种组合预测模型的预测误差均比使用单一的 ARIMA 预测模型的预测误差要小, 说明在处理非平稳的风电功率时间序列中, 对序列进行平稳化预处理对提高预测精度有很大的帮助。根据结论可知, 本文提出的改进方法可以有效地提高风电功率预测的精度, 并且为实现风电在线超短期预测提供了可行性。但是在风电功率波动较大的区间, 本文提出的组合预测模型仍然会在预测时产生较大的误差, 如图 7 中的第一个波峰, 这是由风能具有的随机性和非平稳性造成的, 在本文中只考虑了历史数据中风电功率的波动趋势, 并且以分析历史数据和波动趋势为主进行预测, 如果能将风场的物理因素考虑在内, 就可以进一步跟踪风电功率的波动趋势, 提高风电功率的预测精度。

3 结论

针对风电功率时间序列具有的非线性和非平稳性, 本文提出了一种 MEEME-SE-ARMA 组合预测模型, 相对比目前在处理风电功率时间序列非平稳性中使用的小波变换、EMD 分解和 EEMD 分解方法, MEEMD 分解能够有效地抑制模态混叠和端点失真的现象, 可以更好地分析风电功率的波动趋势。通过对内蒙古赤峰市某一风电场的实际风电功率预测算例分析, 得到以下结论:

1) MEEMD-SE-ARMA 分解法操作简便, 省去了小波变换中对小波基确定的繁琐, MEEMD 分解法改进了 EMD 分解法和 EEMD 分解法中的端点失真、模态混叠和计算量大的问题。

2) 利用 MEEMD-SE-ARMA 分解风电功率时间序列得到了多个 IMF 分量, 为了减少建立预测模型的计算规模, 采用样本熵对各个 IMF 分量进行复杂

度分析, 将样本熵值相近的 IMF 分量进行叠加合并, 生成一组复杂度差异明显的新风电子序列。

3) 对新风电子序列分别使用时间序列法建立 ARMA 预测模型。为了提高模型的预测精度, 将各个 ARMA 模型分别进行拉格朗日乘子(LM)检验, 检验是否满足建立自回归条件异方差(ARCH)预测模型的条件, 进一步提高预测的准确性。

4) 通过对 MEEMD-SE-ARMA 模型、EEMD-SE-ARMA 模型、EMD-SE-ARMA 模型及 ARIMA-GARCH 模型预测结果的对比分析, 可以得出本文提出的 MEEMD-SE-ARMA 组合预测模型大大提高了风电功率超短期预测的精度, 并且减少了计算规模和时间, 为未来的在线风电功率超短期预测做了必要的铺垫。

参考文献

- [1] 廖志刚, 何世恩, 董新洲, 等. 提高大规模风电接纳及送出的系统保护研究[J]. 电力系统保护与控制, 2015, 43(22): 41-46.
LIAO Zhigang, HE Shien, DONG Xinzhou, et al. Research on the system protection for enhancing the accommodation and transmission of large scale wind power[J]. Power System Protection and Control, 2015, 43(22): 41-46.
- [2] 蒋程, 刘文霞, 张建华, 等. 含风电接入的发输电系统风险评估[J]. 电工技术学报, 2014, 29(2): 260-270.
JIANG Cheng, LIU Wenxia, ZHANG Jianhua, et al. Risk assessment of generation and transmission systems considering wind power penetration[J]. Transactions of China Electrotechnical Society, 2014, 29(2): 260-270.
- [3] 卢鹏铭, 温步瀛, 江岳文. 基于多时间尺度协调机组组合的含风电系统旋转备用优化研究[J]. 电力系统保护与控制, 2015, 43(5): 94-100.
LU Pengming, WEN Buying, JIANG Yuewen. Study on optimization of spinning reserve in wind power integrated power system based on multiple timescale and unit commitment coordination[J]. Power System Protection and Control, 2015, 43(5): 94-100.
- [4] 马斌, 张丽艳, 郭成. 一种变权重风电功率最优组合预测模型[J]. 电力系统保护与控制, 2016, 44(5): 117-121.
MA Bin, ZHANG Liyan, GUO Cheng. An optimal combination forecasting model with variable weight for wind power[J]. Power System Protection and Control, 2016, 44(5): 117-121.
- [5] 陈昊. 基于广义自回归条件异方差模型的负荷预测新方法[J]. 电力系统自动化, 2007, 31(15): 51-54, 105.
CHEN Hao. A new method of load forecasting based on

- generalized autoregressive conditional heteroscedasticity model[J]. Automation of Electric Power Systems, 2007, 31(15): 51-54, 105.
- [6] 李玲玲, 许亚惠, 田晓越, 等. 基于组合模型的风电功率短期预测[J]. 电工技术学报, 2014, 29(1): 475-480.
LI Lingling, XU Yahui, TIAN Xiaoyue, et al. Based on the combined model of short-term wind power prediction[J]. Transactions of China Electrotechnical Society, 2014, 29(1): 475-480.
- [7] 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.
- [8] 甘迪, 柯德平, 孙元章, 等. 基于集合经验模式分解和遗传-高斯过程回归的短期风速概率预测[J]. 电工技术学报, 2015, 30(11): 138-147.
GAN Di, KE Deping, SUN Yuanzhang, et al. Short-term wind speed probabilistic forecasting based on EEMD and coupling GA-GPR[J]. Transactions of China Electrotechnical Society, 2015, 30(11): 138-147.
- [9] 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]. Proc R Soc Lond A, 1998, 454(12): 903-995.
- [10] WANG Peng, CHEN Guochu, XU Yufa. Improved empirical mode decomposition and its application to wind power forecasting[J]. Control Engineering of China, 2011, 18(4): 588-591.
- [11] 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.
- [12] 郑旭, 郝志勇, 卢兆刚, 等. 基于 MEEMD 的内燃机机体活塞敲击激励与燃烧爆发激励分离研究[J]. 振动与冲击, 2012, 31(6): 109-113.
ZHENG Xu, HAO Zhiyong, LU Zhaogang, et al. Separation of piston-slap and combustion shock excitations via MEEMD method[J]. Journal of Vibration and Shock, 2012, 31(6): 109-113.
- [13] 郑旭, 郝志勇, 金阳, 等. 基于 MEEMD 的内燃机辐射噪声贡献[J]. 浙江大学学报(工学版), 2012, 46(5): 954-960.
ZHENG Xu, HAO Zhiyong, JIN Yang, et al. Studying noise contributions of IC engine via MEEMD method[J]. Journal of Zhejiang University (Engineering Science), 2012, 46(5): 954-960.
- [14] RICHMAN J S, MOORMAN J R. Physiological time-series analysis using approximate entropy and sample entropy[J]. Am J Physiol Heart Circ Physiol, 2000, 278: 2039-2049.
- [15] 张学清, 梁军, 张熙, 等. 基于样本熵和极端学习机的超短期风电功率组合预测模型[J]. 中国电机工程学报, 2013, 33(25): 33-40, 8.
ZHANG Xueqing, LIANG Jun, ZHANG Xi, et al. Combined model for ultra short-term wind power prediction based on sample entropy and extreme learning machine[J]. Proceedings of the CSEE, 2013, 33(25): 33-40, 8.
- [16] 蔡凯, 谭伦农, 李春林, 等. 时间序列与神经网络法相结合的短期风速预测[J]. 电网技术, 2008, 32(8): 82-85.
CAI Kai, TAN Lunnong, LI Chunlin, et al. Short-term wind speed forecasting combining time series and neural network method[J]. Power System Technology, 2008, 32(8): 82-85.

收稿日期: 2016-03-08; 修回日期: 2016-04-25

作者简介:

田波(1990-), 女, 通信作者, 硕士研究生, 研究方向为地方电力系统自动化; E-mail: tianbo900512@163.com

朴在林(1955-), 男, 教授, 博士生导师, 研究方向为地方电力系统自动化; E-mail: piaozl@china.com

郭丹(1982-), 女, 博士, 讲师, 研究方向为地方电力系统自动化。E-mail: goldenflying123@163.com

(编辑 魏小丽)