

DOI: 10.7667/PSPC171866

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

陈昊¹, 张建忠², 许超¹, 谭风雷¹

(1. 国网江苏省电力有限公司, 江苏 南京 210024; 2. 东南大学, 江苏 南京 210096)

摘要: 基于对风电功率时间序列波动性多重机制的研究, 提出一种基于多重离群点平滑转换自回归模型(M-OSTAR)的风电功率预测方法。运用一种改进条件极大似然估计方法, 获得 M-OSTAR 模型的参数估计。考虑风电波动性的厚尾效应, 将 M-OSTAR 模型推广为厚尾形式。进一步借助所提模型的机制转换参数, 描述了风电时间序列的多重离群点效应。此外, 给出了一种新型的波动性分析工具——标准信息冲击曲面, 分析了风电时间序列条件方差的动态变化特征。基于实际风电数据的算例验证了基于 M-OSTAR 族模型预测方法的可行性与有效性。

关键词: 多重离群点平滑转换自回归模型; 双重离群点效应; 风电功率预测; 厚尾效应

Short-term wind power forecast based on MOSTAR model

CHEN Hao¹, ZHANG Jianzhong², XU Chao¹, TAN Fenglei¹

(1. State Grid Jiangsu Electric Power Co. LTD, Nanjing 210024, China; 2. Southeast University, Nanjing 210096, China)

Abstract: Based on the analysis on the different regimes in the volatility of wind power time series, a prospective wind power forecasting method based on Multiple Outlier Smooth Transition Autoregressive (MOSTAR) type models is presented. By modifying Conditional Maximum Likelihood Estimate (CMLE), the parameters of the MOSTAR models are obtained. Considering the fat-tail effect in the volatility of wind power time series, MOSTAR models with fat-tail distribution are proposed for generalization. Moreover, with the regime switching parameter of the proposed model, the multiple outlier effect of real case is depicted more rigorously. In addition, Standard News Impact Surface (SNIS), a refined tool for volatility analysis is provided to analyze the dynamic varying characteristics of conditional variance. Case studies on a practical wind power data validate the feasibility and effectiveness of M-OSTAR type model.

This work is supported by National Natural Science Foundation of China (No. 51577025) and Natural Science Fund for Colleges and Universities in Jiangsu Province (No. 14KJB470003).

Key words: multiple OSTAR model; double outlier effect; wind power forecast; fat tail effect

0 引言

清洁替代是当今全球能源发展的重要趋势^[1]。风能作为近年来发展迅猛的清洁能源, 长期为人瞩目。据全球风能理事会统计^[2], 截至 2016 年底, 全球风电装机总容量已达 486.8 GW, 再创历史新高。其中, 中国 2016 年新增风电装机容量 23.4 GW, 总装机容量已达到 168.7 GW, 已超过欧盟各国的总装机容量之和。随着风电相关技术的进步和环境保护压力的持续加大, 在可预见的将来, 中国风电还

将迅猛发展。到 2020 年, 我国风电并网装机容量将在 2 亿 kW 以上。

风电场输出功率预测对于电力系统调度部门的调度计划安排、电网状态评估等工作具有重要意义。随着风电渗透率的持续提高, 风电功率波动性对电网的影响也日益为人瞩目。基于对风电时间序列波动特征的分析, 如何捕捉更多有助于提升预测精度的信息, 是亟需深入研究的课题。

目前, 对风电功率预测的常见方法可分为物理方法、统计方法和空间相关性方法三大类^[3-4]。物理预测方法由于其计算过程非常复杂, 且往往要依赖气象、地形等要素, 对于需要频繁给出预测结果的风电功率预测, 物理方法有时难以满足要求。由于

基金项目: 国家自然科学基金项目资助(51577025); 江苏省高校自然科学基金项目资助(14KJB470003)

历史数据序列反映了流体、热力、地形地貌等因素的影响^[3], 统计方法可以回避物理机理掌握不足的难题, 其常见方法有经典时间序列分析模型(如 ARMA^[5])、现代时间序列分析模型^[6-7]、混沌理论^[8]、神经网络^[9-10]、支持向量机模型^[11]、混合方法^[12]等。空间相关性方法^[13]是一类利用分风场周围地区天气信息改进本风场预测的方法, 被认为是未来进一步提升风电预测水平的研究方向。研究表明^[3]: 以 ARMA 为代表的时序分析模型, 具有建模简单、计算量少的特点, 适用于在气象信息有限、历史数据充分情况下的风电预测。现代时间序列分析模型适用场合和 ARMA 模型类似, 在建模上更着眼于从历史数据中研究风电时间序列波动性特征, 进而提升风电预测精度。文献[6]提出了一种基于经典 ARMA-GARCH 的风电预测模型, 分析了风电时间序列的波动集聚效应。文献[7]分析风电时间序列离群点效应(Outlier Effect), 提出了基于 OSTAR 模型的风电预测方法。

目前, 对风电时间序列波动性机制特征的研究一般着眼于刻画单一特征的简单机制转换, 对更复杂的机制转换的研究还不充分。现实中某些风电时间序列可能存在着更为复杂的转换机制, 已剖析的机制中可能还蕴藏有另一层次的机制, 缺乏对多重机制深入分析不利于风电预测精度的改善。本文分析了风功率时间序列波动性多重机制, 提出了一种基于多重离群点平滑转换自回归模型的风电预测方法, 通过算例验证了模型预测能力。

1 M-OSTAR-GARCH 模型

1.1 离群点平滑转换自回归模型

风电功率波动性特征虽和外生冲击具有显著的相关关系, 但这种关系是非线性和时变的^[7]。当外生冲击的幅值超过某个阈值时, 风电功率波动和外生冲击可能不再服从原有的函数关系, 随着冲击幅度的进一步增加, 可能过渡到另一种新的函数关系, 谓之离群点效应。为描述这种两机制特性, 文献[7]提出了一种离群点平滑转换自回归(Outlier Smooth Transition Autoregressive, OSTAR)模型描述风电时间序列波动的离群点效应。

一般地, OSTAR 模型形如式(1)。

$$y_t = \Phi'_0 x_t + F(x; \Delta, \gamma) \Phi'_1 x_t \quad (1)$$

式中: Φ'_0 、 Φ'_1 为系数矩阵; 平滑转换函数 $F(x; \Delta, \gamma)$ 为满足 $0 \leq F(\cdot) \leq 1$ 的连续函数且满足 $F(x; \Delta, \gamma) =$

$$\frac{1}{1 + \exp(-\gamma(|x| - \Delta))}。$$

1.2 M-OSTAR 模型

经典 OSTAR 模型是基于两机制的机制转换模型^[14]。基于两机制的简单机制转换模型已可以描述多数风电场风电时间序列, 但是某些风电时间序列波动性成因复杂, 甚至存在着多种“机制”。对某风电时间序列两种机制进行剖分后, 可能发现机制内部还可以细分出其他机制, 如果这种机制的细分能充分发掘风电时间序列的信息, 则有必要将简单两机制转换模型推广为多重机制转换模型。

考虑到实际风电场风电时间序列波动效应可能具有更加复杂的结构, 这里提出了一种多重离群点平滑转换自回归(Multiple Outlier STAR, M-OSTAR)模型。M-OSTAR 模型形如式(2)。

$$y_t = \Phi'_0 x_t + F_1(s_{1t}; \Delta_1, \gamma_1) \Phi'_1 x_t + F_2(s_{2t}; \Delta_2, \gamma_2) \cdot \Phi'_2 x_t + \dots + F_n(s_{nt}; \Delta_n, \gamma_n) \Phi'_n x_t + \varepsilon_t \quad (2)$$

式中, 平滑转换函数 $F_i(s_{it}; \Delta_i, \gamma_i)$ 满足 $F_i(s_{it}; \Delta_i, \gamma_i) = \frac{1}{1 + \exp(-\gamma_i(|s_{it}| - \Delta_i))}$ ($i = 1, \dots, n$)。

特别地, 当 $n=2$ 时, D-STAR (Double Outlier STAR)模型具备描述时间序列三重机制的能力, 记作 D-OSTAR。

1.3 M-OSTAR 与 GARCH 模型的结合

分析风电时间序列的波动性时, 考虑到风电时间序列的波动集聚效应^[15-16], 将 MOSTAR 模型和 GARCH 族模型相结合, 建立二阶矩层面的 M-OSTAR 即 M-OSTAR-GARCH 模型。考虑到已观察到的风电时间序列的双重离群点效应($n=2$), 所提出的 D-OSTAR-GARCH(p, q)模型形如式(3)一式(7)。

$$y_t = E(y_t | \psi_{t-1}) + \varepsilon_t \quad (3)$$

$$\varepsilon_t = \sqrt{h_t} v_t, \quad v_t \sim \text{i.i.d.} \quad (4)$$

$$h_t = \alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^p \beta_j h_{t-j} + \gamma_1 F_{1_OSTAR}(\varepsilon_{t-1}; \Delta, \gamma_1) \cdot \varepsilon_{t-1}^2 + \gamma_2 F_{2_OSTAR}(\nabla \varepsilon_{t-1}; \Delta, \gamma_2) \varepsilon_{t-1}^2 \quad (5)$$

$$F_{1_OSTAR}(\varepsilon_{t-1}; \Delta, \gamma_1) = \frac{1}{1 + \exp(-\gamma_1(|\varepsilon_{t-1}| - \Delta))} \quad (6)$$

$$F_{2_OSTAR}(\nabla \varepsilon_{t-1}; \Delta, \gamma_2) = \frac{1}{1 + \exp(-\gamma_2(|\nabla \varepsilon_{t-1}| - \Delta))} \quad (7)$$

式中: $E(v_t) = 0$, $E(v_t^2) = 1$; $E(y_t | \Omega_{t-1})$ 为基于 $t-1$ 时刻信息集 Ω_{t-1} 的 y_t 条件均值; 参数 γ_1 、 γ_2 称为机制转换参数。离群点效应参数 γ_1 表征风电时间序列的离群点效应; 参数增量离群点效应参数 γ_2 表征风电时间序列的增量层面的离群点效应。标准情况下, 进一步有 $v_t \sim \overset{\text{i.i.d.}}{N}(0, 1)$ 。

2 M-OSTAR 模型的推广

2.1 v_t 分布的推广

风电功率时间序列常呈现出高峰度的特征。将条件分布设定为正态分布的 M-OSTAR-GARCH 模型在一定程度上可以描述风电时间序列的这种特征,但在另一些高峰度特征显著且呈现出极厚的厚尾特征的场合,正态分布有时会力有未逮。为进一步强化描述风电序列厚尾的能力,可将式(4)中的 v_t 由服从正态分布推广为服从非高斯分布(一般为厚尾分布,如算例中的标准 t 分布与标准广义误差分布),以提高风电场风电功率预测系统的预测精度。

2.2 厚尾多重离群点 STAR 模型

基于对模型 v_t 的推广,将 D-OSTAR-GARCH 模型推广为厚尾 D-OSTAR-GARCH 模型。当 v_t 推广为自由度为 n 的标准 t 分布,即有 $v_t \stackrel{i.i.d.}{\sim} t(0,1;n)$, 得到 D-OSTAR-GARCH- t 模型。将 v_t 推广为具有厚尾参数 ν 的标准广义误差分布(Generalized Error Distribution, GED),即有 $v_t \stackrel{i.i.d.}{\sim} GED(0,1;\nu)$, 得到 D-OSTAR-GARCH-GED 模型。

算例部分将 D-OSTAR-GARCH 模型、D-OSTAR-GARCH- t 模型和 D-OSTAR-GARCH- GED 模型分别记为 D-OSTAR、D-OSTAR- t 和 D-OSTAR-GED。进一步,将三种模型统称为 D-OSTAR 族模型。

3 M-OSTAR 模型的参数估计与机制重数确定方法

3.1 参数估计

M-OSTAR 模型及其他多重机制转换模型的参数估计问题比一般 GARCH 模型更为复杂。尽管 M-OSTAR 似然函数的可获得性较好,可以使用条件极大似然估计(Conditional Maximum Likelihood Estimation, CMLE),但模型结构的复杂性导致模型对参数初始值赋值十分敏感,极易出现结果不收敛的情况。此时需要对初始值特别考虑,同时采用适当的迭代控制方法。本文给出了一种改进 CMLE 方法,该方法亦适用于其他似然函数可得的多重机制转换模型。下面以 D-OSTAR 模型为例给出参数估计步骤。

(1) 建立一个具有与 D-OSTAR 类似结构的辅助 GARCH 模型($v_t \stackrel{i.i.d.}{\sim} N(0,1)$),运用常规 CMLE 估计该模型参数,并将参数估计结果作为下一步的辅助初值;

(2) 建立一个具有与 D-OSTAR 类似结构的辅助

混合冲量门限 GARCH 模型^[17],初始值采取步骤(1)确定的辅助初值,获取该模型的参数估计,作为双重机制转换模型参数的初值;

(3) 运用 CMLE 获取 D-OSTAR 模型参数估计,同时使用 BHHH 算法^[18]控制迭代过程。

(4) 以基于正态分布的双重机制转换模型的参数估计为初始值,运用 CMLE 获取双重机制转换模型(基于非高斯分布)参数估计,同时使用 BHHH 算法控制迭代过程。

3.2 机制重数确定方法

基于 3.1 节的参数估计方法,实践层面有两类机制重数确定方法。

(1) 基于数据的机制重数确定方法

a) 令 $i=1$,建立 MOSTAR(1)模型,估计模型参数。

b) 检验模型的参数显著水平(尤其是机制转换参数的显著性水平)同时检验模型平稳性、二阶平稳性等性质。如检验结果不佳,则执行步骤 c);如检验结果良好,则令 $i=i+1$,建立 M-OSTAR(i)模型,重复执行步骤 b)。

c) 将 M-OSTAR 模型的机制重数确定为 $i-1$ 。特别地,如 $i=1$,则建立无机制转换的常规 GARCH 模型。

(2) 基于先验知识的机制重数确定方法

利用某种统计特征观察到机制重数 i ,直接建立 M-OSTAR(i)模型,进而进行参数估计与模型诊断,如果该模型性质良好,则认为 M-OSTAR 模型重数确定为 i ;如果模型性质不佳,则认为先验知识对本数据不适用,使用上一种方法基于数据重新确定机制重数。

4 M-OSTAR 的标准信息冲击曲面

信息冲击曲线(News Impact Curve, NIC)是研究不同性质冲击对时间序列波动性的影响的重要分析工具^[19]。通过将 $t-2$ 时刻及之前的信息保持为常数,刻画 ε_{t-1} 和 h_t 之间的函数关系。

考虑到 M-OSTAR 结构中具有 ε_{t-1} 、 $\nabla \varepsilon_{t-1}$ 等多个维度,经典 NIC 已无法表征 MOSTAR 模型中的风电波动性。为刻画多维信息对风电时间序列波动性复杂机制转换特征的影响,将 NIC 加以推广,提出一种标准信息冲击曲面(Standard News Impact Surface, SNIS)。以 D-OSTAR 为例的 SNIS 构建方法如下:

(1) 将 $t-2$ 时刻及之前的信息保持为常数;

(2) 使用离群点效应参数和增量离群点效应参数连接 ε_{t-1} 、 $\nabla \varepsilon_{t-1}$ 与 h_t ;

(3) 将空间曲面最低点平移至空间原点。
易见, 此时 SNIS 的表达式为

$$h_t = \alpha_1 \varepsilon_{t-1}^2 + \gamma_1 F_{1_OSTAR}(\varepsilon_{t-1}) \varepsilon_{t-1}^2 + \gamma_2 F_{2_OSTAR}(\nabla \varepsilon_{t-1}) \varepsilon_{t-1}^2 \quad (8)$$

5 算例分析

5.1 数据与建模步骤

算例基于盐城地区某滨海风电场的风电功率数据进行建模及预测。考虑到与文献中时间序列分析类别风电预测模型的可比性, 以及与实际运行风电预测系统中的时间序列模型预测精度相比较的需要, 算例仅使用 2011 年以后的风电功率历史数据进行风电功率预测。具体建模用样本为 2013 年 4 月 1 日至 4 月 7 日数据, 样本间隔为 5 min(每日 288 数据点), 共计 2 016 个样本点。

通过差分方法获取平稳的风电序列, 建立 D-OSTAR 族模型, 利用参数估计值分析多重离群点效应。基于 D-OSTAR 族模型进行迭代式多点预测, 通过将预测值累加还原, 求得 4 月 8 日的全天 288 点风电功率(预测间隔为 5 min), 据此考核 D-OSTAR 模型的风电功率预测能力。

5.2 检验与模型参数估计

5.2.1 平稳性检验与高阶 ARCH 效应检验

将所研究风电功率时间序列记为 Y_t , 这里同时运用增广迪克富勒(ADF)检验和菲利普斯-佩龙(PP)检验考察 Y_t 的平稳性。两种检验的相伴概率分别为 0.756 和 0.769, 均明显大于 0.05, ADF 检验和 PP 检验结果一致表明: Y_t 是不平稳的。进一步对该风电时间序列进行一阶差分变换, 如式(9)。

$$y_t = Y_t - Y_{t-1} \quad (9)$$

再次运用上述两种检验方法验证差分序列 y_t 的平稳性。易得, 两种检验的相伴概率均小于 0.000 1, 即两种检验一致表明原假设应拒绝。此时 y_t 平稳, 满足建模前提条件。

进一步分析 y_t 序列的自相关函数(ACF)和偏自相关函数(PACF), 筛选出具有可行阶数的 ARMA 模型集合, 再依次计算集合中所有备择模型的贝叶斯许瓦兹准则, 遴选出阶数最为适当的 ARMA(5, 4), 以此作为初始 ARMA 模型。

同时引入 LM 检验和鲁棒 MQ 检验考察初始 ARMA 模型的 ε_t 。LM 检验针对不同滞后阶数的相伴概率小于 0.000 1, 鲁棒 MQ 检验结果和 LM 检验结果相同, 即: 风电时间序列存在显著的高阶 ARCH 效应, 满足 GARCH 族模型的建模要求。

5.2.2 D-OSTAR 模型的参数估计

应用文献[7]的模型定阶方法和 3.2 节基于数据的机制重数确定方法, 将模型设定为 ARMA(5,4)-D-OSTAR-GARCH(1,1)模型(简记为 D-OSTAR 模型)。此时, 模型条件均值方程为

$$y_t = \omega + \sum_{j=1}^5 \phi_j y_{t-j} + \varepsilon_t + \sum_{i=1}^4 \theta_i \varepsilon_{t-i} \quad (10)$$

条件方差方程为

$$h_t = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \beta_1 h_{t-1} + \gamma_1 F_{1_OSTAR}(\varepsilon_{t-1}; \Delta_1, \gamma_1) \varepsilon_{t-1}^2 + \gamma_2 F_{2_OSTAR}(\nabla \varepsilon_{t-1}; \Delta_2, \gamma_2) \varepsilon_{t-1}^2 \quad (11)$$

式中, Δ 取为辅助模型 $\tilde{\varepsilon}_t$ 的 2 倍标准差, γ_1 、 γ_2 的确定方法亦依照文献[7]。

使用改进 CMLE, 可获取 D-OSTAR 模型的参数估计如表 1 所示, 相应的 z 统计量亦见表 1。

表 1 D-OSTAR 模型的参数估计

Table 1 Parameter estimate of D-OSTAR model		
	D-OSTAR 模型	z 统计量
C	0.119 9	0.794 8
AR(1)	0.775 2	17.844 9
AR(5)	0.071 03	4.219 4
MA(1)	-0.518 5	-9.424 1
MA(4)	-0.052 83	-2.214 9
Ω	0.258 2	8.149 2
α_1	0.167 3	7.800 8
β_1	0.812 8	62.420 5
γ_1	-0.088 93	-3.543 8
γ_2	0.113 6	4.263 2
AIC	4.969 1	
SIC	4.997 0	
迭代次数	50	

由表 1 可知:

(1) 模型的离群点效应参数 γ_1 为负, 且参数显著性水平良好, 可见风电时间序列波动存在着不同机制。本期幅值充分大的冲击(正负冲击皆然), 对未来波动性的影响有被抑制的倾向。风电时间序列波动性存在离群点效应在此亦得到支持。

(2) 模型的增量离群点效应参数 γ_2 为正, 且参数显著性水平良好。易见, 经典离群点效应之外, 风电时间序列波动存在另一重不同机制。本期幅值充分大的冲击增量, 对未来波动性的影响有被助增的倾向。风电时间序列波动性存在增量离群点效应在此亦得到支持。

由于风电时间序列的厚尾效应^[6], 考虑将 D-OSTAR 模型推广为厚尾 D-OSTAR 模型, 使用 CMLE, 估计 D-OSTAR-t、D-OSTAR-GED 模型的

参数, 结果见表 2。其中, n 为标准 t 分布的自由度参数, ν 为广义误差分布的形状参数。

表 2 厚尾 D-OSTAR 的参数估计

Table 2 Parameter estimate of fat tailed D-OSTAR				
	D-OSTAR-t 模型 z 统计量		D-OSTAR-GED 模型 z 统计量	
C	0.153 9	1.109 3	0.150 8	1.087 6
AR(1)	0.761 3	15.186 9	0.765 3	16.331 1
AR(5)	0.074 84	3.122 6	0.073 11	3.499 0
MA(1)	-0.512 2	-8.586 7	-0.513 1	-9.014 6
MA(4)	-0.048 06	-1.971 6	-0.050 49	-2.129 0
Ω	0.135 6	3.292 2	0.194 2	4.677 8
α_1	0.157 4	6.267 9	0.167 3	6.006 3
β_1	0.846 8	47.105 5	0.827 2	45.183 4
γ_1	-0.097 82	-2.992 2	-0.099 15	-3.037 5
γ_2	0.072 35	2.248 1	0.092 93	2.859 7
n	8.266 1	7.350 9	—	—
ν	—	—	1.445 992	28.729 5
AIC	4.931 0		4.939 3	
SIC	4.961 6		4.970 0	
迭代次数	24		37	

由表 2 可知:

(1) D-OSTAR-t、D-OSTAR-GED 模型的参数 γ_1 均显著, 且符号均为负, 关于风电波动离群点效应的结论和 D-OSTAR 模型相一致。D-OSTAR-t、D-OSTAR-GED 模型的参数 γ_2 均显著, 且符号相同均为正, 即关于风电波动增量离群点效应的结论亦与 D-OSTAR 模型一致。算例中风电时间序列波动性存在双重离群点效应得到了印证。

(2) D-OSTAR-t 模型的标准 t 分布 n 参数显著性水平良好; D-OSTAR-GED 模型的 GED 形状参数 $\nu = 1.445 992 < 2$, 参数显著且通过厚尾效应判据验证, 即满足式(12)。

$$2 - \hat{\nu} > 0.84 \times \hat{\sigma}_\nu \quad (12)$$

可见, 两种模型的 ν 参数一致表明风电序列呈现出厚尾特征。因此, 经典 D-OSTAR 模型推广为厚尾 D-OSTAR 具有合理性。

5.3 D-OSTAR 的 SNIS

基于参数估计和式(9)可以绘制 D-OSTAR 的标准信息冲击曲面(SNIS), 如图 1。

图 1 描述了风电时间序列条件方差 h_t 和 ε_{t-1}^2 、 $\nabla \varepsilon_{t-1}$ 的函数关系。由图 1 可知:

(1) 当 $\nabla \varepsilon_{t-1} = C$ 时, D-OSTAR 模型的标准信息冲击曲面为一条开口向上的曲线, 将该曲线命名为 $A_{\nabla \varepsilon_{t-1}}$ 。 $A_{\nabla \varepsilon_{t-1}}$ 关于 $\varepsilon_{t-1} = 0$ 左右对称, 且在门限参数 Δ_1 附近实现两条抛物线之间平滑过渡。因 γ_1 参数为

负, 当 $|\varepsilon_{t-1}| \ll \Delta_1$ 时, ε_{t-1}^2 对 h_t 的影响保持着一个相对大的权重; 随着 $|\varepsilon_{t-1}|$ 增大, ε_{t-1}^2 对 h_t 影响的权重有所减小。该结论与 OSTAR 模型的结论保持一致, 风电时间序列的离群点效应得以验证。

(2) 以 $|\varepsilon_{t-1}| = \Delta_2$ 为分界面, 曲线 $A_{\nabla \varepsilon_{t-1}}$ 存在显著变化, 由于增量离群点效应参数为正, 当 $|\varepsilon_{t-1}| \ll \Delta_2$ 时, ε_{t-1}^2 对 h_t 的影响保持着一个相对小的权重。随着 $|\varepsilon_{t-1}|$ 幅值上升, ε_{t-1}^2 对 h_t 影响的权重不断加大。由于平滑转换函数在定义域内可微保证了不同机制间过渡的平滑性。特别指出的是, $\nabla \varepsilon_{t-1}$ 是通过调控 ε_{t-1}^2 对 h_t 产生影响来实现其对 h_t 的影响的, 图 1 中 SNIS 曲面起伏明显, 可见算例中这种影响是显著的, 此亦为算例中风电时间序列增量离群点效应存在性的又一依据。

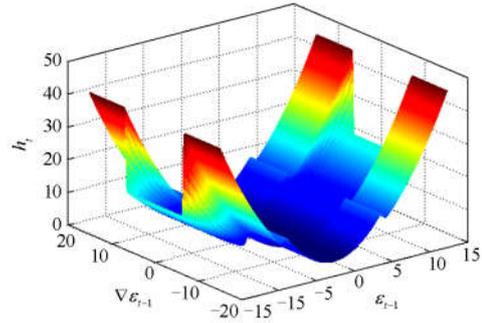


图 1 D-OSTAR 的标准信息冲击曲面

Fig. 1 SNIS of D-OSTAR

5.4 预测结果比对与分析

将表 1、表 2 估计的参数值应用于 D-OSTAR 族模型, 实现未来 288 点预测, 进而基于式(9)由差分序列复原出风电功率预测值, 如式(13)。

$$\hat{Y}_t = Y_{t-1} + \hat{y}_t \quad (13)$$

这里, \hat{y}_t 依次使用 3 种 D-OSTAR 族模型。

根据式(13)可以得到基于 D-OSTAR 族模型的盐城某风电场 4 月 8 日的 288 点风电功率。

分别采用均方误差 E_{RMSE} 、平均绝对误差 E_{MAE} 以及平均绝对百分误差 E_{MAPE} 对风电预测模型的结果进行评价。3 种预测评价指标形如式(14)一式(16)。

$$E_{RMSE} = \sqrt{\sum_{t=T+1}^{T+h} (\hat{y}_t - y_t)^2 / h} \quad (14)$$

$$E_{MAE} = \sum_{t=T+1}^{T+h} |\hat{y}_t - y_t| / h \quad (15)$$

$$E_{MAPE} = \sum_{t=T+1}^{T+h} \left| \frac{\hat{y}_t - y_t}{y_t} \right| / h \times 100\% \quad (16)$$

3 种 D-OSTAR 族模型的风电预测结果如表 3 所示。亦应用持续模型、ARMA、GARCH 及其 OSTAR 模型分别基于算例数据进行风电功率预测, 结果亦见表 3。

表 3 预测结果比较

Table 3 Comparison of forecasting performance

模型名称	E_{RMSE}	E_{MAE}	$E_{MAPE} / \%$
持续模型	16.449 5	12.036 7	17.468
ARMA	5.130 8	3.408 7	4.693 2
GARCH	5.125 3	3.412 1	4.700 3
OSTAR	5.122 4	3.410 8	4.688 7
D-OSTAR	5.125 0	3.400 7	4.686 8
D-OSTAR-t	5.112 5	3.398 4	4.683 9
D-OSTAR-GED	5.117 2	3.398 4	4.683 5

由表 3 可得到以下结论:

(1) 基于 E_{RMSE} 和 E_{MAE} 指标, D-OSTAR-t 模型预测精度最高; 而基于 E_{MAPE} 指标, D-OSTAR-GED 模型预测精度最高。

(2) 考虑多重离群点效应的 D-OSTAR 模型预测效果优于考虑常规离群点效应的 OSTAR 模型, 更优于不考虑离群点效应的 GARCH 模型。算例中引入计及双重离群点效应的传递函数对提高预测精度有积极意义。

(3) 仅就基于 3 种不同分布的 D-OSTAR 族模型而言, 计及厚尾效应的 D-OSTAR 模型预测精度优于正态 D-OSTAR 模型。可见, 采用非高斯分布(t 和 GED 等厚尾分布)有利于风电预测效果。

进而给出 D-OSTAR-t 模型的预测结果如图 2。宽度为 $2\hat{\sigma}$ 的预测区间和实际风电功率值, 亦见图 2。

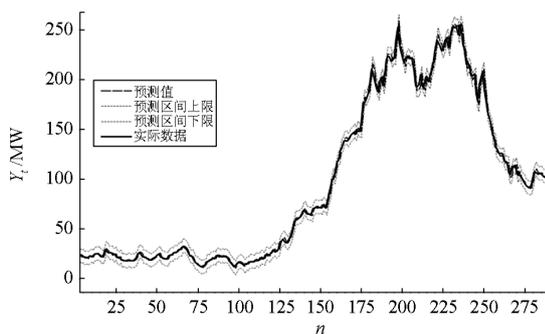


图 2 D-OSTAR-t 模型的预测值

Fig. 2 Forecasting value based on D-OSTAR-t model

由图 2 可以看出, 预测曲线与实际曲线吻合度较高, 仅有个别数据点在预测区间之外, 以 D-OSTAR-t 模型为代表的厚尾 D-OSTAR 模型预测效果良好。

6 结论

基于对风电波动性机制的分析, 提出了一种多重离群点平滑转换自回归族风电预测模型。

1) D-OSTAR 族风电预测模型能有效描述风电时间序列波动性的多重机制。

2) 本文提出的基于改进 CMLE 的 D-OSTAR 族模型的参数估计方法, 可操作性强, 适用于多机制 STAR 模型的参数估计。

3) 算例表明, 以 D-OSTAR-t 和 D-OSTAR-GED 为代表的厚尾多重离群点平滑转换自回归模型, 可以有效描述风功率序列复杂的转换机制, 适用于在气象信息有限、风电功率历史数据充分的情况下的风电预测, 亦可为实际风电预测系统的基准模型的选定提供参考。

4) 提出了一种基于标准信息冲击曲面的多重离群点效应的分析框架, 研究了多维信息对风电时间序列波动性的影响。基于 SNIC 提出风电功率波动性的量化指标从而服务于风电功率的准确预测是下一步研究的重点。

参考文献

- [1] 刘振亚. 全球能源互联网[M]. 北京: 中国电力出版社, 2015: 85-97.
- [2] GWEC. Global wind report annual market[EB/OL]. <http://gwec.net/publications/global-wind-report-2/global-wind-report-2016/> 2017-4-28/2017-12-25.
- [3] 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.
- [4] 杨正瓴, 冯勇, 熊定方, 等. 基于季风特性改进风电功率预测的研究展望[J]. 智能电网, 2015, 3(1): 1-7. YANG Zhengling, FENG Yong, XIONG Dingfang, et al. Research of prospects of improvement in wind power forecasting based on characteristics of monsoons[J]. Smart Grid, 2015, 3(1): 1-7.
- [5] 高阳, 朴在林, 张旭鹏, 等. 基于噪声场合下 ARMA 模型的风力发电量预测[J]. 电力系统保护与控制, 2010, 38(20): 164-167. GAO Yang, PIAO Zailin, ZHANG Xupeng, et al. Prediction of wind power generation based on ARMA with additive noise model[J]. Power System Protection and Control, 2010, 38(20): 164-167.
- [6] 陈昊, 万秋兰, 王玉荣. 基于厚尾均值广义自回归条件异方差族模型的短期风电功率预测[J]. 电工技术学报,

- 2016, 31(5): 91-98.
- CHEN Hao, WAN Qiulan, WANG Yurong. Short-term wind power forecast based on fat-tailed generalized autoregressive conditional heteroscedasticity-in-mean type models[J]. Transactions of China Electrotechnical Society, 2016, 31(5): 91-98.
- [7] CHEN H, LI F, WANG Y. Wind power forecasting based on outlier smooth transition autoregressive GARCH model[J]. Journal of Modern Power Systems and Clean Energy, 2018, 6(3): 532-539.
- [8] 江岳春, 张丙江, 邢方方, 等. 基于混沌时间序列 GA-VNN 模型的超短期风功率多步预测[J]. 电网技术, 2015, 39(8): 2160-2166.
- JIANG Yuechun, ZHANG Bingjiang, XING Fangfang, et al. Super-short-term multi-step prediction of wind power based on GA-VNN model of chaotic time series[J]. Power System Technology, 2015, 39(8): 2160-2166.
- [9] 马斌, 张丽艳. 一种基于径向基神经网络的短期风电功率直接预测方法[J]. 电力系统保护与控制, 2015, 43(19): 78-82.
- MA Bin, ZHANG Liyan. Short-term wind power direct forecasting based on RBF neural network[J]. Power System Protection and Control, 2015, 43(19): 78-82.
- [10] ZHENG Dehua, ESEYE A T, ZHANG Jianhua, et al. Short-term wind power forecasting using a double-stage hierarchical ANFIS approach for energy management in microgrids[J]. Protection and Control of Modern Power Systems, 2017, 2(2): 136-145. DOI: 10.1186/s41601-017-0041-5.
- [11] 李燕青, 袁燕舞, 郭通. 基于 AMD-ICSA-SVM 的超短期风电功率组合预测[J]. 电力系统保护与控制, 2017, 45(14): 113-120.
- LI Yanqing, YUAN Yanwu, GUO Tong. Combination ultra-short-term prediction of wind power based on AMD-ICSA-SVM[J]. Power System Protection and Control, 2017, 45(14): 113-120.
- [12] 张颖超, 郭晓杰, 叶小岭, 等. 一种短期风电功率集成预测方法[J]. 电力系统保护与控制, 2016, 44(7): 90-95.
- ZHANG Yingchao, GUO Xiaojie, YE Xiaoling, et al. An integrated forecasting method of short-term wind power[J]. Power System Protection and Control, 2016, 44(7): 90-95.
- [13] 薛禹胜, 陈宁, 王树民, 等. 关于利用空间相关性预测风速的评述[J]. 电力系统自动化, 2017, 41(10): 161-169.
- XUE Yusheng, CHEN Ning, WANG Shumin, et al. A review on wind speed prediction based on spatial correlation[J]. Automation of Electric Power Systems, 2017, 41(10): 161-169.
- [14] TERÄSVIRTA T, ANDERSON H M. Characterizing nonlinearities in business cycles using Smooth Transition Autoregressive models[J]. Journal of Applied Econometrics, 1992, 7(12): 119-136.
- [15] ENGLE R F. Autoregressive conditional heteroskedasticity with estimate of the variance of U.K. inflation[J]. Econometrica, 1982, 50(4): 987-1008.
- [16] BOLLERSLEV T. Generalized autoregressive conditional heteroskedasticity[J]. Journal of Econometrics, 1986, 31(3): 307-327.
- [17] 陈昊. 采用现代时间序列分析方法的电力负荷预测[M]. 北京: 中国电力出版社, 2015: 139-142.
- [18] BERNDT E, HALL B, HALL R, et al. Estimation and inference in nonlinear structural models[J]. Annals of Economic and Social Measurement, 1974, 3(4): 653-665.
- [19] ENGLE R, NG V. Measuring and testing the impact of news on volatility[J]. Journal of Finance, 1993, 48(5): 1749-1778.

收稿日期: 2017-12-25; 修回日期: 2018-05-22

作者简介:

陈昊(1980—), 男, 通信作者, 博士, 研究员级高工, 研究方向为能源预测, 电力系统保护与控制。E-mail: pingfengma@126.com

(编辑 魏小丽)