

DOI:10.12158/j.2096-3203.2022.05.013

基于不同分布下 GARCH-M 族模型的短期用户负荷预测

王晨¹, 叶江明¹, 何嘉弘²

(1. 南京工程学院电力工程学院, 江苏 南京 211167;

2. 东南大学电气工程学院, 江苏 南京 210096)

摘要: 电力负荷预测是电力系统研究的基础工作之一, 而时间序列分析法是目前使用最广泛的预测方法。针对用户日度负荷时间序列存在的波动性及尖峰厚尾特征, 文中提出利用均值广义自回归条件异方差(GARCH-M)族模型进行用户负荷预测。首先根据用户日度负荷时间序列的分布情况, 利用拉格朗日乘数(LM)检验方法检验了负荷序列的自回归条件异方差(ARCH)效应; 其次提出在高斯分布、 t 分布和广义误差分布(GED)3种不同分布下, 根据波动补偿项的不同形式, 建立 GARCH-M 族模型; 最后结合损失函数进行预测分析, 结果表明相比传统时间序列分析模型, 在不同分布下的 GARCH-M 族模型提高了短期用户负荷预测准确度。

关键词: 时间序列分析法; 短期用户负荷预测; 自回归条件异方差(ARCH)效应; GARCH-M 族模型; 厚尾效应; 损失函数

中图分类号: TM715

文献标志码: A

文章编号: 2096-3203(2022)05-0110-06

0 引言

由于电力市场化的不断推进以及需求侧管理要求的不断提高, 对于负荷预测的精度要求也越来越高^[1-3]。目前, 国内外对于负荷预测理论和模型的研究有一定的进展, 如时间序列分析^[4]、灰色系统理论^[5]、神经网络模型^[6-8]、支持向量机^[9]、模糊聚类^[10-11]等。文献[12]提出了一种卷积神经网络和长期记忆网络的混合模型, 能有效提升预测精度, 但数据的获取存在困难。文献[13]针对非平稳的负荷序列提出了小波分解法, 但小波基的不确定往往影响着预测结果。文献[14]提出了利用粒子群算法寻找最小二乘支持向量机(least squares support vector machines, LS-SVM)模型的最优参数, 但 SVM 的计算复杂程度会增加预测实施的困难。

以自回归滑动平均(autoregressive moving average, ARMA)模型为代表的时序分析法建模方法成熟、理论基础坚实、数据需求量少、方程简单而预测表现较好, 是一种使用广泛的负荷预测方法^[15-18]。文献[19]提出了一种基于广义自回归条件异方差(generalized autoregressive conditional heteroskedasticity, GARCH)模型的负荷预测方法, 取得了较 ARMA 模型更好的预测结果, 却未考虑负荷序列波动性对其条件均值的影响。文献[20]研究了风电功率序列的厚尾效应, 验证了均值广义自回归条件异方差(GARCH-in-mean, GARCH-M)模型的有

效性。GARCH 模型能有效刻画时间序列条件方差的时变特征, 是刻画时间序列波动性的经典主流模型之一^[21]。

从实际用户日度负荷序列中发现, 条件均值与条件方差之间存在关联性, 同时自由分量的分布存在不对称性且具有尖峰厚尾特性。而 GARCH-M 族模型恰好能够表达负荷时间序列条件方差与条件均值之间的直接关系, 且在一定程度上能够刻画负荷时间序列有偏、尖峰厚尾的特性。因此, 文中在高斯分布、 t 分布和广义误差分布(generalized error distribution, GED)3种分布下分别建立 GARCH-M 族模型来拟合负荷曲线, 并进行样本外预测和分析。

1 GARCH-M 族模型理论

1.1 GARCH 模型

Tim Bollerslev 提出的 GARCH(p, q)模型如式(1)和式(2)所示, 分别为条件均值方程和条件方差方程。

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

$$h_t = \alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^p \beta_j h_{t-j} \quad (2)$$

式中: y_t 为 t 时刻样本序列的值; $\varepsilon_t = \sqrt{h_t} v_t$ 为 t 时刻白噪声; h_t 为 t 时刻样本条件方差; v_t 为序列, 假设服从独立同分布, 且有 $E(v_t) = 0$, $E(v_t^2) = 1$; $E(y_t | \psi_{t-1})$ 为基于 $t-1$ 时刻的信息集 ψ_{t-1} 的 y_t 条件均值; p, q 为模型阶数, 其值均为非负整数; $\alpha_0, \alpha_i, \beta_j$ 为条件方差参数, 且有 $\alpha_0 > 0$, $\alpha_i \geq 0$, $\beta_j \geq 0$, $i = 1, 2, \dots, q$ 和 $j = 1, 2, \dots, p$ 。

收稿日期: 2022-04-07; 修回日期: 2022-06-26

基金项目: 国家自然科学基金资助项目(51807028)

1.2 GARCH-M 模型

将 GARCH 模型进行拓展,形成 GARCH-M 模型^[22-23]。GARCH-M 模型可表示为:

$$y_t = E(y_t | \Psi_{t-1}) + \gamma g(h_t) + \varepsilon_t \quad (3)$$

$$h_t = \alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^p \beta_j h_{t-j} \quad (4)$$

式中: $g(\cdot)$ 为异方差项,一般取条件方差的单调正值函数; γ 为条件均值与条件方差的关联系数。一般将 $g(h_t) = h_t$, $g(h_t) = \sqrt{h_t}$, $g(h_t) = \lg \sqrt{h_t}$ 这 3 种模型分别称为第一型 GARCH-M 模型 (GARCH-M¹)、第二型 GARCH-M 模型 (GARCH-M²)、第三型 GARCH-M 模型 (GARCH-M³)^[23]。

2 预测方法

GARCH 模型预测方法为输入实际的用户日度负荷数据,建立 GARCH 模型对负荷进行预测,输出预测的结果,与实际用户的负荷数据进行比较,具体步骤如下。

步骤 1: 建立 ARMA(p, q) 模型,模型结构如式 (5) 所示^[24]。

$$y_t = \varphi_0 + \varphi_1 y_{t-1} + \varphi_2 y_{t-2} + \cdots + \varphi_p y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \cdots - \theta_q \varepsilon_{t-q} \quad (5)$$

式中: y_{t-k} ($k=1, 2, \dots, p$) 为 t 时刻样本序列的值, ε_t 和 y_{t-k} 独立; φ_p, θ_q 为对应阶数的系数,均为常数。

步骤 2: 提取 ARMA 模型残差。首先对用户日度负荷序列建立 ARMA(p, q) 模型,把去除模型拟合值的残差部分称为自由分量,并定义其为序列 I 。计算序列 I 的均值、中位数、方差、偏度、峰度、Jarque-Bera (JB) 统计量等相关统计量信息。

步骤 3: 进行拉格朗日乘数 (Lagrange multiplier, LM) 检验、建立 GARCH 模型^[25-26]。需要指出的是, GARCH 模型的建立基于自回归模型的随机扰动项,因此首先须检验随机扰动项是否存在 ARCH 效应。具体的做法是,运用 LM 检验法检验步骤 2 中负荷残差序列 I 的波动性,若相关统计量的值显著,则认为序列存在 ARCH 效应,且可使用 GARCH 模型建模。

ARCH 模型的实质为根据序列 I 的平方具有相关性而建立二阶的 ARMA 模型,通过 LM 检验可判断 ARCH 效应的强弱。LM 检验原理为建立关于 ε_{t-q}^2 的辅助回归方程,如式 (6) 所示。

$$h_t = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \cdots + \alpha_q \varepsilon_{t-q}^2 \quad (6)$$

通过检验式 (6) 中所有回归系数是否同时为 0 来判断是否存在 q 阶 ARCH 效应。

步骤 4: 参数估计。首先,分别假定序列 I 服从

高斯分布、 t 分布、GED。 t 分布和 GED 的密度函数表达式分别如式 (7)、式 (8) 所示,其中 λ, ν 均为常数。

$$f_t(x, k) = \frac{\Gamma((k+1)/2)}{[(k-2)\pi]^{1/2} \Gamma(k/2)} \left(1 + \frac{x^2}{k-2}\right)^{-\frac{k+1}{2}} \quad (7)$$

$$f_{\text{GED}}(x, k) = \frac{\nu e^{-0.5|x/\lambda|^\nu}}{\lambda \times 2^{1+\frac{1}{\nu}} \Gamma(1/\nu)} \quad (8)$$

然后,利用条件极大似然估计对 GARCH-M 族模型进行参数估计^[27]。为得到各参数均显著的模型,分析检查各模型参数,去除参数不显著的模型,仅保留各参数值显著的模型。

步骤 5: 预测分析。基于参数估计的情况,列出预测方程如式 (9) 所示。

$$\hat{Y}_t = Y_{t-1} + \hat{y}_t \quad (9)$$

式中: \hat{Y}_t 为 t 时刻样本估计值; Y_{t-1} 为 $t-1$ 时刻样本实际值; \hat{y}_t 为 t 时刻样本序列估计值。并采用均方根误差 (root mean square error, RMSE) E_{RMSE} 、平均绝对误差 (mean absolute error, MAE) E_{MAE} 、平均绝对百分比误差 (mean absolute percentage error, MAPE) E_{MAPE} 3 种损失函数来评价模型的预测效果和预测准确度。各误差指标计算公式如式 (10)~式 (12) 所示。

$$E_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i^* - y_i)^2} \quad (10)$$

$$E_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n |y_i^* - y_i| \quad (11)$$

$$E_{\text{MAPE}} = \frac{1}{n} \sum_{i=1}^n \frac{|y_i^* - y_i|}{y_i} \quad (12)$$

式中: y_i^* 为预测值; y_i 为实际值; n 为样本数据的数量。

3 算例仿真

文中采用某市用户日度负荷序列进行建模,样本空间为 2014 年 1 月 1 日—2017 年 11 月 30 日,共 1 430 个样本点。使用仿真软件 Eviews 建立 GARCH-M 族模型,并分析负荷 GARCH-M 效应,预测 2017 年 12 月 (31 个样本点) 的负荷情况,并利用损失函数分析 GARCH-M 模型的预测效果。

3.1 基本统计量分析

首先,对日度负荷序列样本数据建立 ARMA (3, 2) 模型,得到形如式 (13) 的模型表达式。

$$y_t = 16\,987.46 + 2.025y_{t-1} - 1.597y_{t-2} + 0.559y_{t-3} + \varepsilon_t - 1.090\varepsilon_{t-1} + 0.280\varepsilon_{t-2} \quad (13)$$

其次,根据步骤 2 所述方法提取该模型的序列 I ,绘制序列 I 的直方图,如图 1 所示,并计算相关统计量,如表 1 所示。图 1 中序列 I 的直方图具有明显不同于高斯分布的尖峰厚尾情况,甚至是有偏的。




图 1 频率分布直方图

Fig.1 Frequency distribution histogram

表 1 基本统计量

Table 1 Basic statistics

统计量	数值	统计量	数值
均值	-5.696 5	偏度	0.198 2
中位数	-47.946 4	峰度	4.993 7
方差	1 183.202	JB 统计量	251.551 2

从表 1 来看,偏度为 0.198 2,大于 0,表明序列 I 明显正偏,具有不对称的冲击,且正冲击对负荷的影响大于负冲击;峰度为 4.993 7,这一峰度值显然比高斯分布的峰度值 3 要高,表明序列 I 具有尖峰和厚尾的性质;JB 统计量为 251.551 2,P 值为 0,表明序列 I 不服从高斯分布。

3.2 LM 检验

根据 3.1 节中模型的序列 I 建立辅助回归方程,通过 LM 检验序列 I 的各阶 ARCH 效应。检验结果如表 2 所示。

表 2 各阶 ARCH 效应的 LM 检验结果

Table 2 LM test results of various ARCH effects

滞后阶数 q	F-statistic	P 值	滞后阶数 q	R-squared	P 值
1	9.555 950	0.002	1	9.505 688	0.002
2	13.407 14	0	2	26.374 43	0
3	26.290 80	0	3	74.940 40	0
4	20.320 92	0	4	77.156 23	0
5	16.397 28	0	5	77.835 90	0
6	13.865 32	0	6	78.966 74	0

从表 2 第三列及第六列数据得出,各阶 ($q > 1$) 残差序列的回归方程系数均为 0,证明序列 I 确实有 ARCH 效应,且在较高阶时仍然存在显著的 ARCH 效应。因此,可以对负荷序列建立 GARCH-M 模型。

3.3 参数估计

根据步骤 4 中参数估计方法,去除参数不显著的模型,只保留各参数值显著的模型。以伴随概率、条件均值与条件方差的关联系数,条件方差参数,偏度参数, t 分布自由度,GED 的形状参数,赤池信息准则,施瓦茨准则以及拟合优度等参数值为尺度来衡量各个模型参数的显著性。

3.4 预测分析

首先运用 ARMA 模型和 GARCH 模型根据步骤 5 中的方法对 2017 年 12 月份用户负荷数据进行预测,得到模型预测指标见表 3,预测结果见图 2。

表 3 模型预测指标

Table 3 Model predictors indicators

指标	ARMA 模型	GARCH 模型
E_{RMSE}	897.814 2	876.877 6
E_{MAE}	670.386 3	680.138 5
E_{MAPE}	0.037 32	0.037 85
残差偏度	0.198 2	0.172 0
残差峰度	4.993 7	3.841 0




图 2 模型预测结果

Fig.2 Model prediction results

综合表 3 和图 2 可得,采用 GARCH 模型对 12 月份的数据进行预测结果分析, E_{RMSE} 有了明显的降低, E_{MAE} 和 E_{MAPE} 却高于 ARMA 模型。从残差指标来看,GARCH 模型残差峰度更接近于 3,残差偏度更接近于 0,能更好地表达序列的波动特征。说明在不同指标下预测效果也不同,两者各有优缺点。

因此,在研究 GARCH 模型的基础上,提出用 GARCH-M 族模型来刻画负荷时间序列有偏、尖峰厚尾的特性,随后在高斯分布、 t 分布、GED 3 种条件分布下分别建立 GARCH-M 族模型来拟合负荷曲线,并进行样本外预测和分析。运用各模型分别对 2017 年 12 月数据进行预测,预测公式见式(9),预测效果的比较如表 4 所示,其中 EGARCH 模型为指数 GARCH 模型。

由表 3、表 4 可得出以下结论:

- (1) 从残差峰度、残差偏度指标来看,GARCH-

M 族模型在一定程度上能够刻画残差序列尖峰厚尾的特性。

表 4 预测结果比较

Table 4 Comparison of predicted results

模型	E_{RMSE}	E_{MAE}	E_{MAPE}	残差偏度	残差峰度
GARCH-M ² -GED	939.354 8	701.673 7	0.039 160	0.186 8	4.309 6
GARCH-M ² - <i>t</i>	840.761 5	659.834 7	0.037 122	0.164 5	4.104 0
GARCH-M ³ -GED	838.607 9	648.183 5	0.036 662	0.152 1	4.006 2
GARCH-M ³ - <i>t</i>	840.922 4	652.602 7	0.036 989	0.167 2	4.085 2
EGARCH-M ² -N	853.024 6	684.508 4	0.038 771	0.165 4	4.153 1
EGARCH-M ² -GED	840.834 4	661.382 3	0.037 381	0.162 3	4.032 5
EGARCH-M ² - <i>t</i>	866.505 7	618.095 0	0.034 655	0.160 8	4.083 4
EGARCH-M ³ -N	863.440 6	704.228 7	0.039 380	0.179 4	4.168 6
EGARCH-M ³ -GED	848.172 3	678.866 9	0.038 193	0.175 5	4.135 0
EGARCH-M ³ - <i>t</i>	851.967 5	686.333 8	0.038 571	0.174 8	4.139 5

(2) 从 E_{RMSE} 指标来看, GARCH-M³-GED 模型的预测效果最好; 从 E_{MAE} 和 E_{MAPE} 指标来看, EGARCH-M²-*t* 模型的预测效果最好。

(3) 综合所列的全部模型来看, 基于 *t* 分布和 GED 的模型总体预测效果优于基于高斯分布的模型, 采用 *t* 分布或 GED 有利于提高预测准确度。

(4) 算例中采用的 GARCH-M³-GED、GARCH-M³-*t* 以及 EGARCH-M²-*t* 模型表现均较为出色, 实际工程应用时可根据预测需求选择合适的模型。

4 结语

文中通过算例的参数估计结果和预测结果分析, 验证了实际的用户日度负荷时间序列存在有偏、尖峰厚尾的特征。在 ARMA 模型以及 GARCH 模型负荷预测的研究基础上, 提出运用 GARCH-M 族模型与之在预测效果方面进行对比; 同时基于负荷序列的尖峰厚尾特征, 进一步推广了不同分布下 GARCH-M 族模型的短期负荷预测。

算例结果表明, 相较于传统的时间序列模型 (ARMA 模型等), 不同分布下 GARCH-M 族模型预测准确度更高, 其中的 GARCH-M³-GED、GARCH-M³-*t* 以及 EGARCH-M²-*t* 模型在实际预测效果方面表现出色, 在短期用户负荷预测的实际工程应用中有利于提高预测精度。

参考文献:

- [1] 廖旋煊, 胡智宏, 马莹莹, 等. 电力系统短期负荷预测方法综述[J]. 电力系统保护与控制, 2011, 39(1): 147-152. LIAONihuan, HU Zhihong, MA Yingying, et al. Review of the short-term load forecasting methods of electric power system[J]. Power System Protection and Control, 2011, 39(1): 147-152.
- [2] 刘云, 张杭, 张爱民. 需求侧响应下基于负荷特性的改进短期负荷预测方法[J]. 电力系统保护与控制, 2018, 46(13): 126-133. LIU Yun, ZHANG Hang, ZHANG Aimin. Improved load forecasting method based on load characteristics under demand-side response[J]. Power System Protection and Control, 2018, 46(13): 126-133.
- [3] 罗凡, 余向前, 王林信, 等. 基于聚类与自适应划分的短期负荷预测[J]. 电力电容器与无功补偿, 2021, 42(6): 184-189. LUO Fan, YU Xiangqian, WANG Linxin, et al. Short-term load prediction based on clustering and adaptive partition[J]. Power Capacitor & Reactive Power Compensation, 2021, 42(6): 184-189.
- [4] 蒋增林, 叶江明, 陈昊. 基于时间序列分析的负荷预测方法的比较研究[J]. 南京工程学院学报(自然科学版), 2018, 16(2): 26-31. JIANG Zenglin, YE Jiangming, CHEN Hao. A comparative study of load forecasting methods based on time series analysis[J]. Journal of Nanjing Institute of Technology (Natural Science Edition), 2018, 16(2): 26-31.
- [5] 赵海青. 基于累积法的灰色模型及在电力负荷预测中的应用[J]. 中国电力, 2016, 49(S1): 94-95, 101. ZHAO Haiqing. A grey forecasting model for electric power based on cumulative method[J]. Electric Power, 2016, 49(S1): 94-95, 101.
- [6] KONG W C, DONG Z Y, JIA Y W, et al. Short-term residential load forecasting based on LSTM recurrent neural network[J]. IEEE Transactions on Smart Grid, 2019, 10(1): 841-851.
- [7] 祝学昌. 基于 IFOA-GRNN 的短期电力负荷预测方法研究[J]. 电力系统保护与控制, 2020, 48(9): 121-127. ZHU Xuechang. Research on short-term power load forecasting method based on IFOA-GRNN[J]. Power System Protection and Control, 2020, 48(9): 121-127.
- [8] 王凌云, 林跃涵, 童华敏, 等. 基于改进 Apriori 关联分析及 MFOLSTM 算法的短期负荷预测[J]. 电力系统保护与控制, 2021, 49(20): 74-81. WANG Lingyun, LIN Yuehan, TONG Huamin, et al. Short-term load forecasting based on improved Apriori correlation[J]. Power System Protection and Control, 2021, 49(20): 74-81.
- [9] 刘家敏, 李聪睿, 周志浩, 等. 基于 WD-CS-SVM 的超短期风电功率组合预测[J]. 电力工程技术, 2019, 38(5): 24-29. LIU Jiamin, LI Congrui, ZHOU Zhihao, et al. Combination ultra-short-term prediction of wind power based on WD-CS-SVM[J]. Electric Power Engineering Technology, 2019, 38(5): 24-29.
- [10] 孙景钊, 胡长洪, 项焯焯, 等. 基于多核模糊 C 均值聚类的配电网短期负荷预测[J]. 浙江电力, 2022, 41(3): 65-71.

- SUN Jingliao, HU Changhong, XIANG Yeyun, et al. Short-term load forecasting of distribution networks based on multiple kernel fuzzy C-means clustering[J]. Zhejiang Electric Power, 2022, 41(3):65-71.
- [11] 李焱, 贾雅君, 李磊, 等. 基于随机森林算法的短期电力负荷预测[J]. 电力系统保护与控制, 2020, 48(21):117-124.
LI Yan, LI Lei, JIA Yajun, et al. Short term power load forecasting based on a stochastic forest algorithm[J]. Power System Protection and Control, 2020, 48(21):117-124.
- [12] 陆继翔, 张琪培, 杨志宏, 等. 基于 CNN-LSTM 混合神经网络模型的短期负荷预测方法[J]. 电力系统自动化, 2019, 43(8):131-137.
LU Jixiang, ZHANG Qipei, YANG Zhihong, et al. Short-term load forecasting method based on CNN-LSTM hybrid neural network model[J]. Automation of Electric Power Systems, 2019, 43(8):131-137.
- [13] LI B W, ZHANG J, HE Y, et al. Short-term load-forecasting method based on wavelet decomposition with second-order gray neural network model combined with ADF test[J]. IEEE Access, 5:16324-16331.
- [14] 杨小明, 崔雪, 周斌, 等. 基于粒子群优化支持向量机的短期负荷预测[J]. 武汉大学学报(工学版), 2018, 51(8):715-720.
YANG Xiaoming, CUI Xue, ZHOU Bin, et al. Research on short term load forecasting based on particle swarm optimization-support vector machine[J]. Engineering Journal of Wuhan University, 2018, 51(8):715-720.
- [15] 田波, 朴在林, 郭丹, 等. 基于改进 EEMD-SE-ARMA 的超短期风功率组合预测模型[J]. 电力系统保护与控制, 2017, 45(4):72-79.
TIAN Bo, PIAO Zailin, GUO Dan, et al. Wind power ultra short-term model based on improved EEMD-SE-ARMA[J]. Power System Protection and Control, 2017, 45(4):72-79.
- [16] 范金骥. 基于 ARMA 与 ANN 模型组合交叉方法的电网日负荷预测[J]. 浙江电力, 2018, 37(8):35-41.
FAN Jinji. Daily grid load forecasting based on ARMA and ANN model combined crossing method[J]. Zhejiang Electric Power, 2018, 37(8):35-41.
- [17] 于群, 张铮, 屈玉清, 等. 基于 ARMA-GABP 组合模型的电网大停电事故损失负荷预测[J]. 中国电力, 2018, 51(11):38-44.
YU Qun, ZHANG Zheng, QU Yuqing, et al. Power loss prediction of large blackouts in power grid based on ARMA-GABP combined model[J]. Electric Power, 2018, 51(11):38-44.
- [18] 苏振宇, 龙勇, 赵丽艳. 基于 regARIMA 模型的月度负荷预测效果研究[J]. 中国电力, 2018, 51(5):166-171.
SU Zhenyu, LONG Yong, ZHAO Liyan. Study on the monthly power load forecasting performance based on regARIMA model[J]. Electric Power, 2018, 51(5):166-171.
- [19] 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.
- [20] 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.
- [21] BOLLERSLEV T. Generalized autoregressive conditional heteroskedasticity[J]. Journal of Econometrics, 1986, 31(3):307-327.
- [22] NELSON D B. Conditional heteroskedasticity in asset returns: a new approach[J]. Modelling Stock Market Volatility, 1991, 59(2):347-370.
- [23] 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.
- [24] 李孟特, 顾春华, 温蜜, 等. 一种基于 ARMA-BP 组合模型的电压偏差预测方法[J]. 智慧电力, 2020, 48(12):14-19.
LI Mengte, GU Chunhua, WEN Mi, et al. A voltage deviation prediction method based on ARMA-BP combined model[J]. Smart Power, 2020, 48(12):14-19.
- [25] 曾德明. 电力负荷的预测方法的建模与仿真[J]. 计算机仿真, 2011, 28(12):331-334.
ZENG Deming. Modeling and simulation on power load prediction[J]. Computer Simulation, 2011, 28(12):331-334.
- [26] 崔和瑞, 彭旭. 基于 ARIMAX 模型的夏季短期电力负荷预测[J]. 电力系统保护与控制, 2015, 43(4):108-114.
CUI Herui, PENG Xu. Summer short-term load forecasting based on ARIMAX model[J]. Power System Protection and Control, 2015, 43(4):108-114.
- [27] CHEN H, LI F X, WANG Y R. Erratum to: wind power forecasting based on outlier smooth transition autoregressive GARCH model[J]. Journal of Modern Power Systems and Clean Energy, 2019, 7(6):1749.

作者简介:



王晨

王晨(1996),男,硕士,助理工程师,从事负荷预测相关工作(E-mail:15705278163@163.com);

叶江明(1964),男,硕士,教授,研究方向为能源有效综合利用;

何嘉弘(1988),男,博士,副教授,研究方向为高电压与绝缘技术。

Short-term user load forecasting based on GARCH-M family model with different distributions

WANG Chen¹, YE Jiangming¹, HE Jiahong²

- (1. School of Electric Power Engineering, Nanjing Institute of Technology, Nanjing 211167, China;
2. School of Electrical Engineering, Southeast University, Nanjing 210096, China)

Abstract: Power load forecasting is one of the basic tasks power system research, and time series analysis is currently the most widely used forecasting method. Aiming at the fluctuation and the characteristics of peak and thick tail of user daily load time series, the generalized autoregressive conditional heteroskedasticity-in-mean (GARCH-M) family model is proposed to predict user load. Firstly, the autoregressive conditional heteroskedasticity (ARCH) effect of load series is examined by using the Lagrange multiplier (LM) test according to the distribution of user daily load time series. Secondly, under three different distributions of Gaussian distribution, t -distribution and generalized error distribution (GED), the GARCH-M family model is established according to the different forms of fluctuation compensation terms. Finally, combined with the loss function, the prediction analysis results show that the GARCH-M family model with different distributions improves the accuracy of short-term user load prediction compared with the traditional time series analysis model.

Keywords: time series analysis; short-term user load forecasting; autoregressive conditional heteroskedasticity (ARCH) effect; generalized autoregressive conditional heteroskedasticity-in-mean (GARCH-M) family model; fat tail effect; loss function

(编辑 陆海霞)

(上接第 109 页)

Optimal design for thermal energy storage capacity of CSP considering credible capacity

WANG Xiangyan¹, CHEN Ning¹, WANG Weizhou², ZHAO Liang¹, HU Bangjie³, WANG Pei³

- (1. China Electric Power Research Institute Co., Ltd., Nanjing 210003, China;
2. State Grid Gansu Electric Power Company, Lanzhou 730050, China;
3. College of Energy and Electrical Engineering, Hohai University, Nanjing 211100, China)

Abstract: To explore the capacity value of a concentrating solar power (CSP) station, a method to optimize the thermal collection area and thermal storage capacity of a CSP station based on the credible capacity and levelized cost of energy (LCOE) is proposed in this paper. Firstly, generating efficiency model and economical model of CSP station are established in this paper. Secondly, the generation reliability of power generation system is calculated based on sequential Monte-Carlo method, and the particle swarm optimization (PSO) is utilized to search the credible capacity of the CSP station. Then the influences of solar multiple and thermal storage time on capacity credibility and LCOE of CSP station are studied. With credible capacity and levelized cost of energy as the optimization goal, weighted ideal point solution and entropy weight method are utilized to create a single objective optimization function and to determine the index weight respectively. Taking a CSP planning in the northwest as an example, using the region's real solar irradiation data, a model is established. The results show that the capacity credibility of CSP station increases monotonically with the increase of solar multiple and thermal storage time. At the same time, the levelized cost of energy decreases at the first stage and then increases at the second stage. The optimal solar multiple and thermal storage time is obtained under the constraints.

Keywords: concentrating solar power (CSP); thermal energy storage; credible capacity; levelized cost of energy; multi-objective optimization; weighted ideal point method

(编辑 李栋)