

基于 ARIMAX 模型的夏季短期电力负荷预测

崔和瑞, 彭旭

(华北电力大学经济管理系, 河北 保定 071003)

摘要: 夏季城市的短期电力负荷预测不仅与过去的电力负荷数据有关, 并且受温度、风力、降水量等因素影响明显, 存在明显的突变结构。为了对夏季城市的短期电力负荷进行预测, 根据协整理论采用 SAS 软件建立起电力负荷序列与输入序列“温度”之间的 ARIMAX 模型, 充分挖掘序列的内部自相关信息以及序列与序列之间的相关关系。采取最小信息量准则“AIC-SBC”进行比较可知, ARIMAX 模型比经典时间序列 ARMA 模型的信息量要小, 相对误差更小, 拟合结果更为精确, 在存在突变结构且具有显著影响因素的短期电力负荷预测领域具有很高的应用价值。

关键词: 短期电力负荷预测; 时间序列; 协整理论; ARIMAX 模型; 突变结构

Summer short-term load forecasting based on ARIMAX model

CUI Herui, PENG Xu

(School of Economics and Management, North China Electric Power University, Baoding 071003, China)

Abstract: Summer short-term load forecasting in the city is not only related with the past power load data and affected by temperature, wind, precipitation and other factors, etc. Mutation structure is obvious in this data. In order to forecast summer short-term power load in the city, this paper establishes the ARIMAX model between the power load sequence and the input sequence "temperature" based on Cointegration Relation Theory by SAS, fully exploits self-relevant information of the internal sequence as well as the correlation between sequences. It can be seen from the minimum amount of information standards "AIC-SBC", the amount of information about ARIMAX model is smaller than the classic time series method ARMA model and the relative error is smaller. The fitting results are more accurate. This model has a high value under the presence of mutation structure and significant influence factors in the short-term load forecasting field.

This work is supported by National Natural Science Foundation of China (No. 70671039).

Key words: short-term load forecasting; time series; cointegration theory; ARIMAX model; mutant structure

中图分类号: TM714 文献标识码: A 文章编号: 1674-3415(2015)04-0108-07

0 引言

短期电力负荷预测(Short Term Load Forecasting, STLF)一般主要用来预测未来 1 天至 1 周的电力负荷, 其预测的精度直接影响到电力市场下各运营商的经济成本, 因而在现代电力需求侧管理当中占有重要地位。准确的电力负荷预测可以经济合理的安排电网内部发电机组的启用和停止, 保证电网的安全稳定和经济运行, 合理安排机组的检修计划, 优化电力系统调度, 有效降低发电机组的生产成本, 是实施电网优化控制和动态安全分析的前提, 在发展低碳经济的时代背景下具有重要的意义^[1]。

夏季城市的短期电力负荷波动较大, 呈现出明显的趋势性和周期性特征。受温度、风力、降水等气象因素的影响明显, 负荷数据存在显著的突变结构^[2]。传统的电力负荷预测方法有回归分析、灰色模型、支持向量机、神经网络、时间序列等。顾洁、储琳琳(2010)运用变结构协整理论对样本数据突变结构进行处理, 并且采用 GMDH 理论自动搜索结构突变点的变结构协整模型。刘芳、周建中(2009)采取相关向量机的算法来处理非线性时间序列数据, 预测结果较好。徐雅静(2009)运用协整理论结合多元时序分析的 ARIMAX 模型对 GDP 等经济数据进行了相关预测。张刚、刘福潮(2014)采用了 BP-ANN 方法对电网短期负荷进行了预测。刘金朋、牛东晓(2013)采用了一种基于改进的支持向量机和

模拟退火算法相结合的方法对风速进行了预测, 经检验预测精度有了很大提高。朱玲明、王志坤(2014)提出了一种最小二乘支持向量机和粒子群优化技术相结合的预测方法 PSO-LSSVM, 以结构风险最小化原则代替传统的经验风险最小化原则, 得到了良好的预测结果。黄磊、舒杰(2014)提出了基于多维时间序列局部支持向量机回归的微网光伏发电预测的方法, 在短期小样本电力负荷预测领域具有良好的应用价值。以上几种电力负荷预测方法在处理突变数据结构, 智能算法方面预测效果明显, 具有很高的理论价值, 但是实际操作性较差, 受数据、实验设备影响明显, 泛化能力较弱。相对于上面几种电力负荷预测方法, 时间序列预测方法具有预测方法相对简单, 数据需求量小, 建模理论完备, 可操作性强的特点, 在实际的短期电力负荷预测领域具有很强的实践价值。

传统的时间序列预测方法是根据过去的变化趋势来预测未来的序列状况, 突出时间因素在预测当中的作用, 不考虑外界因素对预测序列的影响。因此, 时间序列预测方法是将所有的影响因素都归结到时间这一综合影响因素上的结果, 没有考虑显著因素对预测结果的强势作用。因此传统的时间序列预测方法仅适合短期电力负荷的趋势预测, 且预测精度较差。典型的时间序列数据不是跳跃变化的而应是渐进变化的^[3]。由于城市夏季温度、降水量等气象因素变化明显, 电力负荷数据波动较大, 存在突变结构。为了加强时间序列预测方法的预测精度, 本文运用协整理论, 考虑带输入变量序列 $\{x_t\}$ “温度”的 ARIMAX 模型进行夏季短期电力负荷预测, 有效弥补了传统时间序列没考虑到显著性外界变化导致较大偏差的缺陷, 极大提高了短期时间序列预测方法的预测精度, 推广和深化了时间序列预测方法在短期电力负荷预测领域的应用。

最后通过最小信息量准则的比较可知, ARIMAX 模型具有比传统的 $AR(p)$ 模型、 $ARMA(p, q)$ 模型更小的信息量, 拟合短期电力负荷预测数据效果更为理想^[4]。通过对结果的相对误差分析也可以看出, ARIMAX 模型的相对误差更小, 预测结果精度更高。

1 相关理论模型

时间序列分析方法是一种典型的时域分析方法, 它从序列自相关的角度来揭示序列内部之间的规律。时域分析方法有其固定的分析套路: ① 观察序列特征。② 由特征选择合适的拟合模型。③ 模型检验和优化。④ 用拟合模型来推断序列的性质并预测。

时间序列分析的核心内容是由美国统计学家 G.E.P.BOX 和英国统计学家 G.M.Jenkins 在“Time Series Analysis Forecasting and Control”一书中提出的求和自回归移动平均模型(ARIMA)也称 Box-Jenkins 模型。在时间序列分析中有几个重要的概念需要重点分析。

平稳性: 设 $\{x_t\}$ 为时间序列, $m \in \mathbb{Z}^*$, $t_1, t_2, \dots, t_m \in T$, 对 $\forall \tau \in \mathbb{Z}$, $\exists F_{t_1, t_2, \dots, t_m}(x_1, x_2, \dots, x_m) = F_{t_1+\tau, t_2+\tau, \dots, t_m+\tau}(x_1, x_2, \dots, x_m)$ 称时间序列 $\{x_t\}$ 为严平稳序列。

纯随机性: 设时间序列 $\{x_t\}$ 满足性质

$$\textcircled{1} \forall t \in T, \exists EX_t = \mu \quad \textcircled{2} \forall t, s \in T, \text{ 有 } \gamma(t, s) =$$

$$\begin{cases} \sigma^2, t = s \\ 0, t \neq s \end{cases}, \text{ 称序列 } \{x_t\} \text{ 为纯随机序列, 或 white noise 序列。简记 } X_t \sim WN(\mu, \sigma^2)。$$

定义 1: 我们把具有如下结构的模型称之为自回归移动平均模型, 记作 $ARMA(p, q)$ 。

$$\begin{cases} x_t = \phi_0 + \phi_1 x_{t-1} + \dots + \phi_p x_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} \\ \phi_p \neq 0, \theta_q \neq 0 \\ E(\varepsilon_t) = 0, Var(\varepsilon_t) = \sigma_\varepsilon^2, E(\varepsilon_t \varepsilon_s) = 0, s \neq t \\ E(x_s \varepsilon_t) = 0, \forall s < t \end{cases}$$

引入延迟算子 B , 可以将 $ARMA(p, q)$ 记作 $\Phi(B)x_t = \Theta(B)\varepsilon_t$ 。

协整理论: Granger 在 1987 年提出了协整理论。设自变量序列为 $\{x_1\}, \dots, \{x_k\}$, 响应序列为 $\{y_i\}$,

建立回归模型 $y_t = \beta_0 + \sum_{i=1}^k \beta_i x_{it} + \varepsilon_t$, 若残差序列 $\{\varepsilon_t\}$ 平稳, 那么说响应序列 $\{y_t\}$ 与自变量序列 $\{x_1\}, \dots, \{x_k\}$ 具有协整关系。有了协整的概念, 这样以来就并不要求所有序列均平稳, 只要两序列之间存在协整关系。协整检验的典型方法是 EG 检验^[5-6]。

前面考虑的都是不带输入变量的平稳时间序列的建模方法, 考虑到因变量或者说响应变量可能受到自变量的影响, 且非平稳序列很难分析, 为此 Cox 和 Jenkins 提出了带输入变量的 ARIMA 模型, 即动态回归模型 ARIMAX。

定义 2: 假设响应变量 $\{y_t\}$ 与输入变量序列 $\{x_1\}, \dots, \{x_k\}$ 均平稳, 建立响应序列和输入变量序

列的回归模型:
$$\begin{cases} y_t = \mu + \sum_{i=1}^k \frac{\Theta_i(B)}{\Phi(B)} B^i x_{it} + \varepsilon_t \\ \varepsilon_t = \frac{\Theta(B)}{\Phi(B)} a_t \end{cases}, \text{ 记为}$$

ARIMAX 模型。

2 ARIMAX 模型建模过程

2.1 建模步骤

① 为满足 ARIMA 模型的方差齐性假设条件的要求, 拟对原始的响应序列 $\{y_i\}$ 和输入序列 $\{x_i\}$, \dots , $\{x_k\}$ 均进行对数变换。

② 检验响应序列和输入序列的对数变换序列 $\{\ln y_i\}$; $\{\ln x_i\}$, \dots , $\{\ln x_k\}$ 它们的平稳性。若已平稳则进入下一步; 若不平稳, 则对对数序列进行差分运算, 并再次进行平稳性检验, 若还不平稳进行二阶差分运算直到满足平稳性要求。

③ 对进行 n 阶差分后平稳的输入序列 $\{\nabla^n \ln x_i\}$

建立 ARMA 模型, $\nabla^n \ln x_{it} = \frac{\Theta_{xi}(B)}{\Phi_{xi}(B)} \varepsilon_{xit}$ 。

④ 对进行 n 阶差分后平稳的响应序列 $\{\nabla^n \ln y_i\}$

建立 ARMA 模型, $\nabla^n \ln y_{it} = \frac{\Theta_{yi}(B)}{\Phi_{yi}(B)} \varepsilon_{yit}$ 。

⑤ 考察 n 阶差分后平稳的对数序列 $\nabla^n \ln y_i$ 和 $\nabla^n \ln x_i$ 的相关系数, 确定 ARIMAX 模型的结构

$$y_i = \mu + \sum_{i=1}^k \frac{\Theta_i(B)}{\Phi_i(B)} B^l x_{it} + \varepsilon_i$$

⑥ 拟合残差序列 $\{\varepsilon_i\}$, $\varepsilon_i = \frac{\Theta(B)}{\Phi(B)} a_i$ 其中 $\{a_i\}$

为零均值白噪声序列。

2.2 建模流程(图 1)

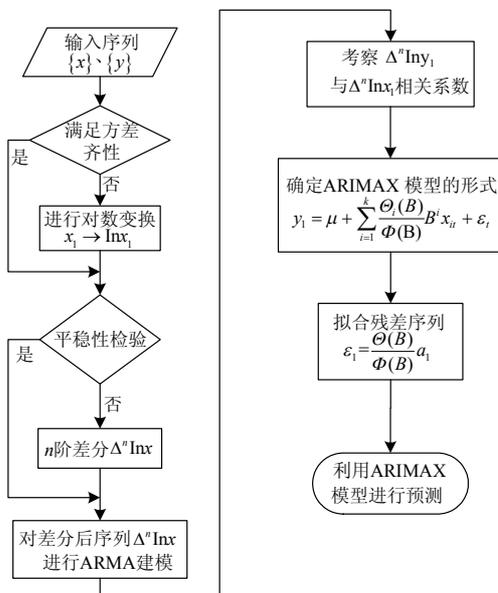


图 1 ARIMAX 模型建模流程图

Fig. 1 ARIMAX modeling flow chart

3 应用 ARMA 模型的夏季短期电力负荷预测

3.1 电力负荷数据

表 1 列出了某市八月份的日最大电力负荷数据和当日的最高气温。本文以表 1 中数据为例, 探究在 SAS 软件环境下的夏季短期电力负荷预测的经典时间序列分析方法 ARMA 模型。在此基础上, 第 4 部分结合序列的自回归作用以及相关序列的影响, 建立带输入序列“温度、风力、降雨量”等气象因素的动态回归模型 ARIMAX^[7-8]。

表 1 2010 年某市每日最大电力负荷数据及最高温度

Table 1 Daily maximum power load and temperature

data of a city in 2010

日期	日最大电力负荷/kWh	日最高温度/℃	日期	日最大电力负荷/kWh	日最高温度/℃
8月1日	2 999	36.7	8月15日	3 190	38.2
8月2日	3 256	38	8月16日	2 685	31
8月3日	3 286	38.7	8月17日	2 833	35.4
8月4日	3 404	39.5	8月18日	2 924	35.9
8月5日	3 464	40.5	8月19日	3 112	37.9
8月6日	2 766	32.9	8月20日	2 393	27.9
8月7日	2 646	33.9	8月21日	2 570	35
8月8日	2 847	35.7	8月22日	2 689	36.8
8月9日	3 094	36.8	8月23日	2 730	29.3
8月10日	3 310	38.8	8月24日	2 597	31.9
8月11日	3 348	39	8月25日	2 216	25.3
8月12日	3 357	37.5	8月26日	1 935	22.4
8月13日	3 290	37.8	8月27日	1 826	23.1
8月14日	3 265	37.8			

利用 SAS 软件对 8 月 1 日至 8 月 31 日的某市日最大电力负荷数据作时序图, 通过观察图形特征, 发现某市 8 月份电力负荷总体呈下降趋势, 存在明显的周期性波动, 序列非平稳。

3.2 ARMA 建模

自相关图(如图 2 所示)显示前半段序列的自相关系数一直为正, 后半段序列自相关系数一直为负, 同时呈现出正弦波动规律, 结合前面的关于时序图的分析可以推测, 某市 8 月份的电力负荷是具有周期性变化的非平稳序列。偏自相关图显示除了一阶偏自相关系数显著大于 2 倍标准差, 二阶开始偏自相关系数迅速向零衰退, 在 2 倍标准差范围内小值随机波动, 近似看作一阶截尾。自相关系数白噪声检验, 统计量的 P 值均小于 0.05, 该序列为非白噪声序列。由此, 拟采取建立 AR(1) 模型对序列进行

预测。对 $AR(1)$ 模型进行残差自相关系数检验, 残差序列 P 值均显著大于 0.05, 模型显著成立, 拟合模型有效。

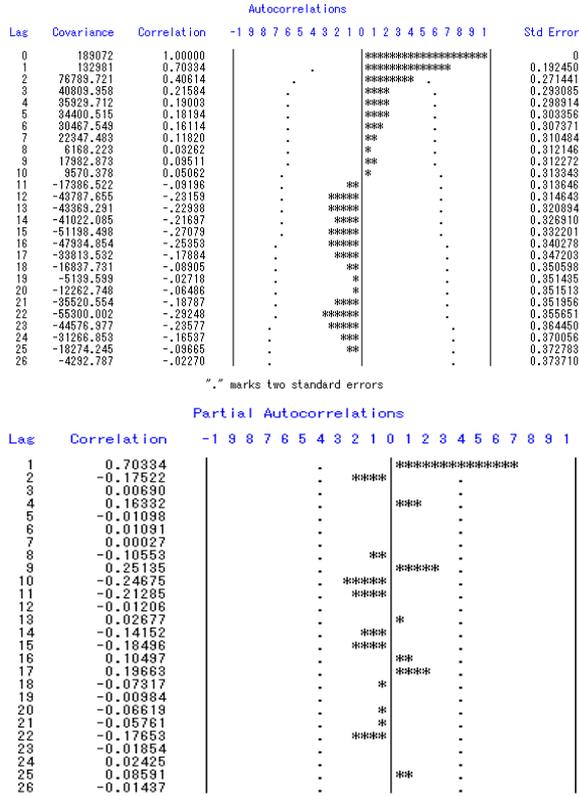


图 2 自相关图和偏自相关图

Fig. 2 Autocorrelation and partial autocorrelation figure

运用 SAS 软件建模, $AR(1)$ 模型表示为 $x_t = 2895.82 + \frac{\varepsilon_t}{1 - 0.90534 \cdot B}$ 。为了对模型进一步优化, 根据最小信息量 AIC-SBC 准则, 采用 SAS 系统中的 minic 选项识别相对最优阶。当把 $ARMA(p, q)$ 模型表述为 $x_t = \mu + \frac{\Theta(B)}{\Phi(B)} \varepsilon_t$ 时, minic 选项识别为 $ARMA(3, 2)$ 模型^[9-10]。

$$x_t = 2949.334 + \frac{1 - 0.97485B + 0.3208B^2}{1 - 1.97331B + 1.49699B^2 - 0.52368B^3} \varepsilon_t$$

4 基于协整理论的 ARIMAX 模型的夏季短期电力负荷预测

4.1 统计量检验

由 DF 检验发现, 无论考虑哪一种模型 τ 检验统计量的 P 值均显著大于 0.05, 因此某市 8 月份的日最大电力负荷数据序列 $\{y_t\}$ 显著非平稳。因此, 下面本文对数据进行非平稳序列分析。为了使得序列满足 ARIMAX 模型的方差齐性要求, 采取对原

始序列进行对数变换即 $x, y \rightarrow \ln x, \ln y$ 。对 $\ln x$ 序列的进行白噪声检验, 结果表明 $\ln x$ 序列是一个非白噪声序列。单位根检验, τ 统计量的 P 值显著大于 0.05, $\ln x$ 序列显著非平稳, 至少存在一个单位根。 $\ln y$ 序列的类似性质同理可得^[11]。

为了使序列平稳, 拟对 $\{\ln y_t\}$ 和 $\{\ln x_t\}$ 序列同时进行一阶差分运算, 得到 $\{\Delta \ln y_t\}$ 和 $\{\Delta \ln x_t\}$ 序列。对差分后的对数序列进行平稳性和白噪声检验, 检验结果显示 $\{\Delta \ln y_t\}$ 和 $\{\Delta \ln x_t\}$ 序列的白噪声检验的 P 值均大于 0.05, 即 $\{\Delta \ln y_t\}$ 和 $\{\Delta \ln x_t\}$ 均为纯随机白噪声序列。 τ 统计量的 P 值均小于 0.05, 即 $\{\Delta \ln y_t\}$ 和 $\{\Delta \ln x_t\}$ 序列均为平稳序列。

4.2 $\Delta \ln y_t$ 和 $\Delta \ln x_t$ 序列建模

首先, 本文对 $\Delta \ln y$ 进行建模。检验显示 $\Delta \ln y$ 为平稳的白噪声序列, 根据最小信息量准则显示拟合的模型为 $\Delta \ln y = \varepsilon_t$ 。

其次, 对 $\Delta \ln x$ 建模。检验显示 $\Delta \ln x$ 为平稳白噪声序列, 根据最小信息量准则显示拟合模型为 $ARMA(0, 1)$ 模型即 $MA(1)$, 并且常数项不显著, 拟合时用 noint 选项去除截距。如图 3 所示, 最终的拟合模型^[12]为 $\Delta \ln x_t = (1 - 0.39758B)\varepsilon_t$ 。

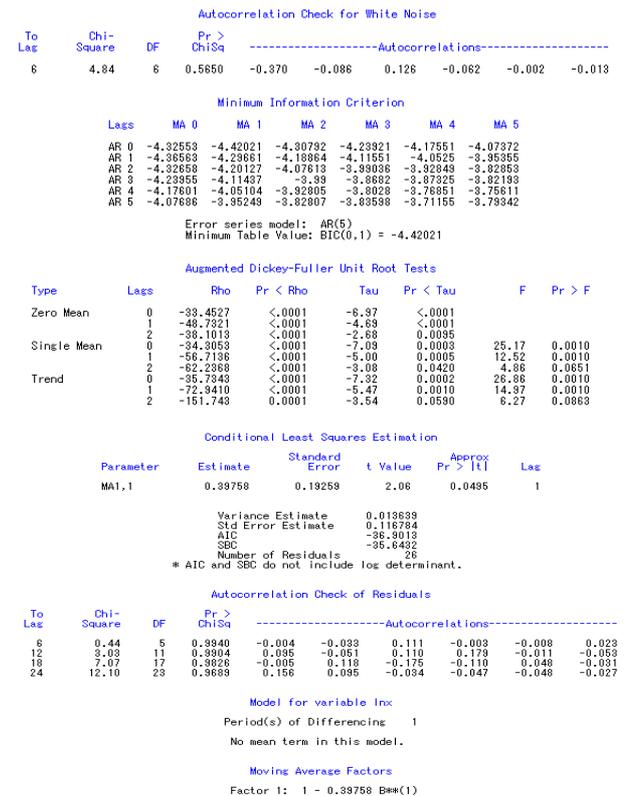


图 3 $\Delta \ln x$ 的建模数据检验及拟合模型

Fig. 3 Testing of $\Delta \ln x$ modeling data and fitting model

4.3 带输入变量序列的 ARIMAX 模型

运用上述模型对输入变量序列 $\{\Delta \ln x_1\}$, ..., $\{\Delta \ln x_k\}$ 和响应变量序列 $\{\Delta \ln y_t\}$ 进行过滤, 计算过滤后输入变量序列和响应变量序列的互相关系数。

如图 4、图 5 所示, 从 $\Delta \ln y_t$ 和 $\Delta \ln x_t$ 序列的相互关系系数图可以看出, 只有延迟 0 阶的相互关系系数显著非零, 即响应序列和输入序列间没有滞后效应, 应当采取同期建模。对 $\Delta \ln y_t$ 与 $\Delta \ln x_t$ 进行回归分析, 发现常数项不显著, 去除常数项, 最终的回归系数为 0.628 71。

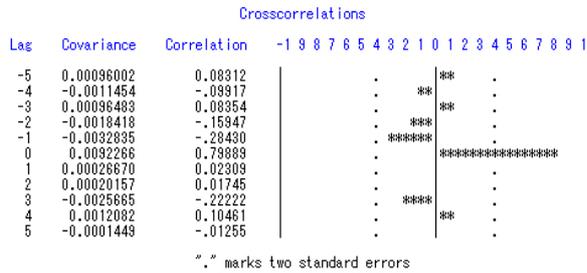


图 4 $\Delta \ln y$ 与 $\Delta \ln x$ 的相互关系系数图

Fig. 4 Relationship number chart of $\Delta \ln y$ and $\Delta \ln x$

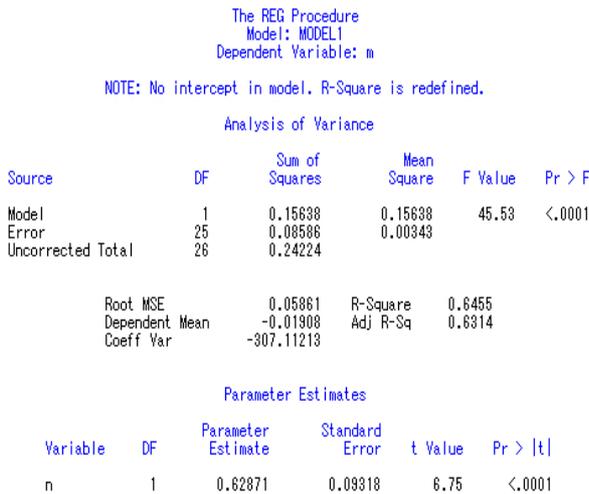


图 5 $\Delta \ln y$ 与 $\Delta \ln x$ 的回归分析

Fig. 5 Regression analysis of $\Delta \ln y$ and $\Delta \ln x$

对残差序列进行统计量检验, 显示残差序列为平稳的白噪声序列, 根据最小信息量显示残差序列的拟合模型为 $\varepsilon_t = a_t$, 其中 a_t 为零均值白噪声序列^[13]。

结合 $\Delta \ln x$ 与 $\Delta \ln y$ 序列的相互关系系数图、回归分析以及残差序列的统计量检验结果, 两序列之间在零阶有显著的相关性, 对 $\Delta \ln y$ 与 $\Delta \ln x$ 进行同期建模。如图 6 所示, 所建立的最终拟合模

$$\text{型为} \begin{cases} \Delta \ln y_t = 0.62871 \Delta \ln x_t + \varepsilon_t \\ \varepsilon_t = a_t \end{cases}$$

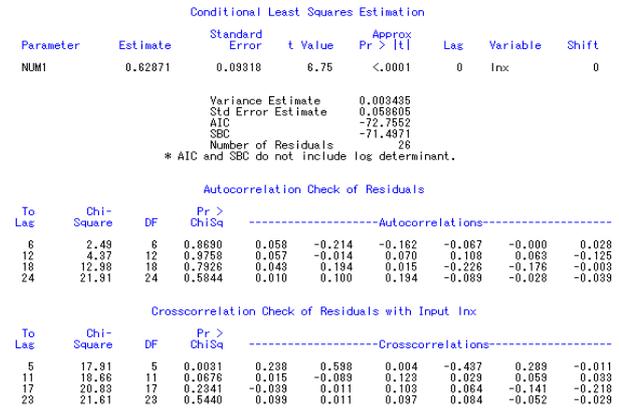


图 6 $\Delta \ln y$ 与 $\Delta \ln x$ 的最终回归拟合模型

Fig. 6 Final regression model of $\Delta \ln y$ and $\Delta \ln x$

根据所建立的 ARIMAX 模型做未来四期预测, 得到 28 日至 31 日的负荷值, 如表 2 所示。

表 2 $\ln y$ 的预测结果

Table 2 Predictions of $\ln y$

Forecasts for variable Lny				
Obs	Forecast	Std Error	95% Confidence Limits	
28	7.538 2	0.093 9	7.339 2	7.707 4
29	7.563 3	0.119 2	7.389 6	7.857 0
30	7.710 0	0.140 0	7.468 8	7.997 7
31	7.722 5	0.158 1	7.413 4	8.133 2

对预测结果进行对数运算得到未来四天的日最大电力负荷预测值。

如表 3 所示, 通过比较模型的相对误差和平均相对误差的大小可以得知, ARIMAX 模型的平均相对误差最小, AR 模型次之, ARMA 模型最大。由最小信息量准则可知, 拟合效果 ARIMAX 模型强于 AR 模型, AR 模型又强于 ARMA 模型, 与平均相对误差的分析结果一致。采取带输入序列的动态回归模型, 将传统的回归分析和时间序列分析方法相结合, 可以对夏季短期电力负荷数据进行有效预测。

最终的拟合图形见图 7。

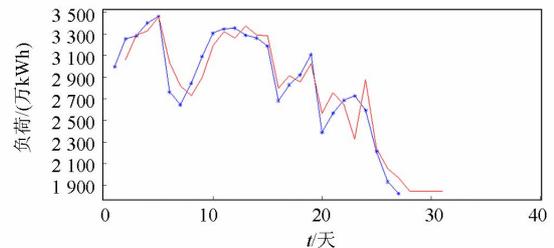


图 7 拟合图形

Fig. 7 Fitting graphics

图 7 中带有星星的折线为实际的日最大电力负荷数据, 另一条折线为拟合的预测数据。其中 $\ln y$ 与 $\ln x$ 回归方程的残差平稳性和白噪声检验显示, 回归方程的残差为平稳的白噪声序列, 即 $\varepsilon_t = a_t$, 且

$\ln y$ 与 $\ln x$ 延迟 2 阶相关, 最终拟合模型为

$$\begin{cases} \ln y_t = 4.51539 + 0.97436 \ln x_{t-2} + \varepsilon_t \\ \varepsilon_t = a_t \end{cases}$$

表 3 不同模型的拟合效果比较

Table 3 Comparison of the effects of different models

预测序列	AIC 信息量	SBC 信息量	1	2	3	4	平均相对误差
AR(1) 模型 预测值	381.4	383.9	1 927.2 (1.6%)	2 018.9 (3.8%)	2 101.9 (-6.3%)	2 177 (-3.7%)	3.9%
ARMA(3, 2) 模型预测值	433.82	436.6	1 968.2 (3.7%)	2 100.1 (7.9%)	2 154 (-4%)	2 137.4 (-5.5%)	5.3%
ARIMAX 模型预测值	-72.75	-71.50	1 850.6 (-0.9%)	1 926.2 (-0.9%)	2 230.5 (-0.6%)	2 258.6 (-0.1%)	0.6%
实际日最大电力负荷数据			1 897	1 945	2 244	2 261	N/A

注: 括号内的百分数为相对误差

5 结论

(1) 含有多个输入变量的时间序列 ARIMAX 模型能够很好的挖掘序列的自相关信息以及序列之间的相关信息。

通过与经典时间序列分析 ARMA 模型比较可知, 运用基于协整理论建立的 ARIMAX 模型进行夏季短期电力负荷预测是一种有效的预测方法。该模型在时间序列预测中除了考虑时间这一唯一影响因素外, 还加入了对序列可能造成较大影响的温度因素, 把自回归和传统回归分析方法相结合, 是一种全新的回归预测模型方法, 预测精度有了很大提高。

(2) 本文考虑了带有一个输入序列“温度”的 ARIMAX 模型。推广而来, 还可以在 SAS 系统中指定多个输入变量, 例如电价、风力、降雨量等, 利用 identify var y=crosscorr x_1, x_2, \dots 结构进行多输入变量的序列预测, 拟合结果将更加准确。

(3) 利用某市 8 月份日最大电力负荷数据及温度, 进行了传统 ARMA 模型和 ARIMAX 模型的电力负荷预测并进行了比较分析。通过对预测模型的信息量大小比较和预测结果的相对误差分析, 均说明带输入变量序列的 ARIMAX 模型的拟合效果较好, 预测精度更高, 对夏季短期季节性电力负荷数据的预测结果较精确。

(4) 由 ARIMAX 模型的预测过程可以看出, 时间序列数据跟事物的发展规律一样, 不仅具有连续性、历史性的特点, 随着时间的推移可能出现新的特点。因此, 在进行时间序列预测时, 不能完全按

序列的过去情况来预测未来情况, 还应当将这些新的特点和影响因素考虑进来, 才能做出更为可靠的时间序列预测结果。

参考文献

[1] 廖旋焕, 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.
LIAO Nihuan, 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] 王东风, 王富强, 牛成林. 小波分解层数及其组合分量对短期风速多步预测的影响分析[J]. 电力系统保护与控制, 2014, 42(8): 82-89.
WANG Dongfeng, WANG Fuqiang, NIU Chenglin. Analysis of wavelet decomposition for multi-step prediction of short-term wind speed[J]. Power System Protection and Control, 2014, 42(8): 82-89.

[3] 王燕. 应用时间序列分析[M]. 北京: 中国人民大学出版社, 2008.

[4] 张翌晖, 王贺, 胡志坚, 等. 基于集合经验模态分解和改进极限学习机的短期风速组合预测研究[J]. 电力系统保护与控制, 2014, 42(10): 29-34.
ZHANG Yihui, WANG He, HU Zhijian, et al. A hybrid short-term wind speed forecasting model based on ensemble empirical mode decomposition and improved extreme learning machine[J]. Power System Protection and Control, 2014, 42(10): 29-34.

[5] FENG Xujie, SUN Quaxin, QIAN Kun, et al.

- Cointegration relationship of regional integrated transport demand and industrial structure[J]. *Journal of Transportation Systems Engineering and Information Technology*, 2012, 6(12): 10-16.
- [6] PEKTAŞ A O, CIGIZOĞLU H K. ANN hybrid model versus ARIMA and ARIMAX models of runoff coefficient[J]. *Journal of Hydrology*, 2013, 50(13): 21-36.
- [7] 牛东晓, 曹树华, 赵磊, 等. 电力负荷预测技术及其应用[M]. 北京: 中国电力出版社, 2008.
- [8] 李欣然, 徐振华, 宋军英, 等. 基于功率空间的分时段负荷模型参数在线修正[J]. *电工技术学报*, 2012, 27(8): 147-156.
- LI Xinran, XU Zhenhua, SONG Junying, et al. On-line revising algorithm for load model parameters of substation in different daily periods based on the measured active power[J]. *Transactions of China Electrotechnical Society*, 2012, 27(8): 147-156.
- [9] ROUT M, MAJHI B, MAJHI RI, et al. Forecasting of currency exchange rates using an adaptive ARMA model with differential evolution based training[J]. *Journal of King Saud University-Computer and Information Sciences*, 2014, 26 (1): 7-18.
- [10] MCMAHON J M, POUGET E R, TORTU S. A guide for multilevel modeling of dyadic data with binary outcomes using SAS PROC NLMIXED[J]. *Computational Statistics & Data Analysis*, 2006, 50(12): 3663-3680.
- [11] 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 Xingjie, MI Zengqiang, YANG Qixun, et al. A novel multi-step prediction for wind speed based on EMD[J]. *Transactions of China Electrotechnical Society*, 2010, 25(4): 165-170.
- [12] 温锦斌, 王昕, 李立学, 等. 基于频域分解的短期风电负荷预测[J]. *电工技术学报*, 2013, 28(5): 66-72.
- WEN Jinbin, WANG Xin, LI Lixue, et al. Short-term wind power load forecasting based on frequency domain decomposition[J]. *Transactions of China Electrotechnical Society*, 2013, 28(5): 66-72.
- [13] LIU Jinpeng, NIU Dongxiao, ZHANG Hongyun, et al. Forecasting of wind velocity: an improved SVM algorithm combined with simulated annealing[J]. *Journal of Central South University*, 2013, 20(2): 451-456.

收稿日期: 2014-05-12; 修回日期: 2014-08-07

作者简介:

崔和瑞(1967-), 男, 博士, 教授, 研究方向为电力系统分析、能源系统理论与政策; Email: cuiherui1967@126.com

彭旭(1990-), 男, 研究生, 研究方向为电力能源消耗、经济计量分析。

(编辑 张爱琴)