

基于时间序列模型的电价预测方法

胡峰, 彭力

(江南大学通信与控制工程学院, 江苏 无锡 214122)

摘要: 通过对美国 PJM 电力市场 2006 年 8 月到 11 月的日前电价的分析研究, 提出了一种基于时间序列的自回归积分滑动平均模型 (ARIMA) 及自回归条件异方差 (ARCH) 模型和神经网络的组合模型来预测美国 PJM 电力市场未来 24 小时的日前电价, 季节性 ARIMA 模型反映了电价趋势性、季节性, ARCH 模型反映了电价的异方差性, 因此该模型能够很好地反映电价的特点, 预测结果良好, 应用前景广阔。

关键词: ARIMA; ARCH; 电价预测; 电力市场; 神经网络

Electricity price forecasting solution based on time series models

HU Feng, PENG Li

(School of Communication and Control Engineering, Jiangnan University, Wuxi 214122, China)

Abstract: Based on the day-ahead price research on the United States PJM electricity market from August to November in 2006, this paper proposes a ARIMA, ARCH and combination model of neural network based on the time series to predict the day-ahead price in future 24 hours of United States PJM electricity market, seasonal ARIMA model reflects the price trend, and seasonal, ARCH models reflect the price's heteroscedasticity, therefore the model can reflect the characteristics of electricity price better, predicted results is excellent and there is broader application prospects.

Key words: ARIMA; ARCH; electricity market; price prediction; neural network

中图分类号: TM715 文献标识码: A 文章编号: 1003-4897(2008)02-0035-06

0 引言

随着电力市场的改革, 电价预测已经成为一种非常有价值的工具。在电力市场交易中, 为了获得有利的竞价或规避风险, 发电商或供电商往往都采用了强有力的电价预测。在实际的电力市场运作中, 电价也是随着需求的变化而变化, 反过来电价变化又影响着需求量。电力市场中各参与者的利益是通过电能交易来实现的, 提前知道电价的相关信息就可以在电力市场的交易中获得更大的利益。因此, 准确的电价预测成了各参与者共同关注的一项重要工作, 是电力市场中亟待解决的问题之一。

短期电价预测是电价预测的重要组成部分, 它主要用于预测未来几小时、1天至几天的电价。准确的短期电价预测将有助于发电商最优报价策略的选择, 从而最大化其利润, 使购电方的动态成本控制成为可能, 同时也为监管部门的实时监管提供了重要的科学依据, 保证电力市场的正常运行。

本文提出了一种基于时间序列的ARIMA, ARCH

双模型及神经网络的组合模型对美国PJM电力市场日前电价的预测的方法。这个模型使用了2006年美国PJM 8到11月的日前电价数据, 用来预测未来24小时的电价。

本文首先介绍了时间序列模型的理论, 接着阐述了ARIMA, ARCH模型的建立及其参数的辨识, 然后提供数据分析在美国PJM电力市场中的应用, 最后得出我们的结论。

1 时间序列和神经网络的基本理论

时间序列模型分为自回归(AR)模型、滑动平均(MA)模型、自回归滑动平均(ARMA)模型、自回归积分滑动平均(ARIMA)模型等, 这些已被广泛应用于短期电价和负荷预测中, 当前比较常用的有ARMA模型, ARIMA模型。这些模型应用的前提都是以时间序列为平稳随机序列为依据。

ARMA是一种典型的时间序列预测模型。它是AR模型和MA模型的结合, 即序列当前值是现在和过去的误差以及先前的序列值的线性组合, 其数学

表达式为:

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

对于通常的回归模型, 如果随机干扰项的平方服从AR(q)过程, 即

$$\varepsilon_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \dots + \alpha_q \varepsilon_{t-q}^2 + \eta_t, \quad t=1, 2, \dots \quad (2)$$

其中: η_t 独立同分布, 并满足 $E(\eta_t) = 0, D(\eta_t) = \lambda^2$, 则称模型是自回归条件异方差模型, 简记为ARCH模型, 称 ε_t 服从 q 阶的ARCH过程, 记为 $\varepsilon_t \sim \text{ARCH}(q)$ 。

由于时间序列方法的主要难点在于如何选择恰当的模型, 如果模型选择不准确, 则即使参数估计再准确, 预测的效果也不会好。而且由于影响电价的因素很多, 时间序列ARMA类模型仅仅考虑了历史电价数据这个因素, 而忽略了影响电价的其他因素, 比如负荷, 天气, 阻塞等等, 因此存在一定的局限性。

人工神经网络适用于处理实际中因不确定性、不精确性等引起的系统难以控制的问题, 映射复杂的输入/输出关系。在各种神经网络中, 反向传播算法BP (Back Propagation Algorithm) 是训练人工神经网络的基本方法, 现已得到了广泛的应用。已有许多将BP神经网络应用于负荷、期货价格以及控制预测等方面的研究, 并取得了不错的效果。神经网络对大量非结构性、非精确性规律具有自适应功能, 能够有效处理多变量和非线性问题, 从而成为目前国内外专家学者研究得比较多的一种电价预测方法。

目前国内外应用于电价预测方面的文献中一般采用的方法有: 时间序列法, 马尔可夫链蒙特卡罗方法, 神经网络, 小波变换, 数据挖掘技术, 支持向量机以及这些方法的综合应用。文献[1]中提出的自回归积分滑动平均模型用来预测未来一天的电价, 文献[2]中提出的广义自回归条件异方差模型用来预测电价的波动率, 文献[3]中提出的广义自回归条件异方差模型用来预测当前电价, 文献[4]使用协整和ARIMA模型分析电负荷需求, 文献[5]使用小波变换和ARIMA模型对日前电价进行预测, 文献[8]使用了模糊神经网络的方法预测日前电价。文献[11]基于神经网络的短期电价预测。

由于电价时间序列的变化常常是一个非平稳的随机过程, 因此在其建模之前对电价数据进行预处理, 使其满足建立模型的基本条件。在此基础上, 本文相应提出了基于时间序列的ARIMA, ARCH和神经网络的组合电价预测模型, 即对一个非平稳电

价时间序列, 先用差分方法将非平稳过程平稳化, 消除电价序列的趋势项和季节项, 使其成为一个平稳的时间序列, 然后采用ARIMA和ARCH模型分别对这个平稳序列建立模型, 然后将这两个模型的预测结果作为神经网络的输入层进行若干次训练, 神经网络的输出将作为最终的电价预测结果。

2 模型的建立与参数的辨识

通过对电价变化规律的分析, 可以知道电价是一个非平稳时间序列。设 y_t 表示这个电价序列。

自相关: 构成时间序列的每个序列值 $y_t, y_{t-1}, \dots, y_{t-n}$ 之间的简单相关关系称为自相关。自相关程度用自相关系数 r_k 表示, 用来度量时间序列中相隔 k 期的观察值之间的相关程度, 用公式表示如下:

$$r_k = \frac{\sum_{t=1}^{n-k} (y_t - \bar{y})(y_{t+k} - \bar{y})}{\sum_{t=1}^n (y_t - \bar{y})^2} \quad (3)$$

其中: n 表示样本量, k 表示滞后期, \bar{y} 表示样本数据的算术平均值。

偏自相关: 是指对于时间序列 y_t , 在给定 $y_{t-1}, \dots, y_{t-k+1}$ 条件下, y_t 与 y_{t-k} 之间的条件相关关系, 其相关程度用偏自相关系数 ϕ_{kk} 度量, 用公式表示如下:

$$\phi_{kk} = \begin{cases} r_1 \\ r_k - \sum_{i=1}^{k-1} \phi_{k-i,i} \cdot r_{k-i} \\ \frac{1 - \sum_{i=1}^{k-1} \phi_{k-i,i} \cdot r_i}{1 - \sum_{i=1}^{k-1} \phi_{k-i,i} \cdot r_i} \end{cases} \quad k=2, 3, \dots \quad (4)$$

MA(p)的自相关和偏自相关函数:

定义MA(q)模型如下:

$$y_t = \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (5)$$

其自相关函数为

$$\rho_k = \begin{cases} -\theta_k + \theta_1 \theta_{k+1} + \dots + \theta_{q-k} \theta_q & 1 \leq k \leq q \\ \frac{1 + \theta_1^2 + \theta_2^2 + \dots + \theta_q^2}{1 + \theta_1^2 + \theta_2^2 + \dots + \theta_q^2} & 0 < k < q \\ 0 & k > q \end{cases} \quad (6)$$

MA(q)序列的自相关函数 ρ_k 在 $k > q$ 以后全都是0, 这个性质称为自相关函数的截尾性, 这个特点可以用来识别自相关函数的阶数。

MA(q)序列的偏自相关函数随着滞后期的增加, 呈现指数或者正弦波衰减, 趋向于0, 这个特性称为偏自相关函数的拖尾性。

AR(p)的自相关和偏自相关函数:

定义AR(p)过程如下:

$$y_t = \varphi_1 y_{t-1} + \varphi_2 y_{t-2} + \dots + \varphi_p y_{t-p} \quad (7)$$

其偏自相关函数满足

$$\phi_{kj} = \begin{cases} \phi_j, 1 < j \leq p \\ 0, p+1 \leq j \leq k \end{cases} \quad (8)$$

换句话说, AR(p)序列的偏自相关函数是 p 步截尾的, 即当 $k > p$ 时, 的值是0, 这个特点可以用来识别自回归模型及确定阶数 p 。

与MA(q)序列相反, AR(p)的自相关函数呈指数或者正弦波衰减, 具有拖尾性。

利用自相关和偏自相关函数的特性和相关图可以对模型进行识别和定阶, ARMA(p, q)模型的自相关函数呈指数或正弦波衰减, 具有拖尾性, 可以用来确定阶数 q , 偏自相关函数随着滞后期的增加也呈现指数或正弦波衰减而趋向于0, 也具有拖尾性, 可以用来确定阶数 p 。

由于电价序列的波动性, 因此序列存在趋势项和季节项, 如图1。

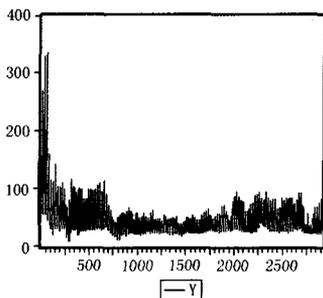


图1 电价序列

Fig.1 Electricity price series

采用 EViews 软件, 通过反复试验检验, 最终确定 ARMA 模型如下:

$$\begin{aligned} x_t = & \phi_1 x_{t-1} + \phi_2 x_{t-2} + \phi_3 x_{t-3} + \phi_4 x_{t-4} + \phi_5 x_{t-5} + \\ & \phi_6 x_{t-6} + \phi_7 x_{t-7} + \phi_{23} x_{t-23} + \phi_{24} x_{t-24} + \phi_{47} x_{t-47} + \\ & \phi_{48} x_{t-48} + \phi_{71} x_{t-71} + \phi_{72} x_{t-72} + \phi_{96} x_{t-96} + \phi_{118} x_{t-118} + \\ & \phi_{120} x_{t-120} + \phi_{144} x_{t-144} + v_t - \theta_1 v_{t-1} - \theta_{22} v_{t-22} \end{aligned} \quad (9)$$

其中: 设 y_t 表示原始时间序列, ly_t 是对 y_t 取自然对数后所得时间序列, x_t 是对 ly_t 进行小时、天的差分后的序列, 即存在滞后项 $(1-B)$, $(1-B^{24})$, ε_t 表示随机误差项。

对这个模型进行误差检验, 在置信度为0.05的情况下, 自相关系数基本全部落在随机区间, 表明这个模型是合理的, 可以用来预测。

同样对这段历史电价数据进行分析, 首先建立 ARMA 模型, 如方程10所示, 对这个模型残差作序列的自相关LM检验时, 可以看出有些自相关系数

明显不落在随机区间, 故存在自相关, 进一步对残差序列进行ARCH效应检验, 重复操作, 可以知道存在 ARCH(2)效应, 因此建立的 ARMA-ARCH 模型如下:

$$\varepsilon_t = \sqrt{h_t} \cdot v_t$$

$$x_t = \phi_1 x_{t-1} + \phi_2 x_{t-2} + \phi_3 x_{t-3} + \phi_4 x_{t-4} +$$

$$\phi_{23} x_{t-23} + \phi_{24} x_{t-24} + \phi_{48} x_{t-48} + \phi_{72} x_{t-72} + \phi_{96} x_{t-96} +$$

$$\phi_{120} x_{t-120} + \phi_{144} x_{t-144} + \phi_{168} x_{t-168} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} \quad (10)$$

神经网络是由处理单元组成的一种并行、分布式信息处理结构, 处理单元之间由单向信道相互连接, 人工神经元是神经网络的基本计算单元, 模拟了人脑中神经元的基本特征, 一般是多输入 / 单输出的非线性单元, 可以有一定的内部状态和阈值, 反向传播算法BP (BackPropagation algorithm)是训练神经网络的基本方法, 已有许多将BP神经网络应用于负荷、期货价格以及控制预测等方面的研究, 并取得了很好的效果。

本文采用BP神经网络来进行预测结果的训练, 具体步骤为: 训练前, 通过ARIMA和ARCH模型分别预测出每个模型的结果, 将此数据预处理作为BP网络的样本输入, 通过反复调整其网络参数, 不断修正, 训练好BP网络, 然后将训练好的网络输出作为该模型的最后预测结果。

该模型中BP网络的设计步骤为: BP网络一般采用3层网络结构, 具有 r 个输入 p , 每个输入都通过一个适当的权值 w 和隐层相连, 网络输出一般

$$a = f(w \times p + b) \quad (11)$$

本文中采用2个24维向量作为输入数据, 输出预测结果为1个24维向量。根据BP网络隐层节点设计的经验公式

$$N_2 = \sqrt{N_1 \cdot N_3} + \alpha \quad (12)$$

其中: N_1 , N_2 , N_3 分别表示输入层、隐层、输出层的节点数, α 取1~10。通过反复训练修正, 于是选取 $N_2=7$ 作为隐层节点数。

3 算例分析

本文使用的数据是来自美国PJM电力市场2006年8到11月的2928个日前电价数据。由于电价序列波动比较大, 于是通过自然对数转换, 使其方差更加平稳。通过分别分析原始序列 y_t , 取自然对数后所得时

间序列 y_t , 进行1, 2阶差分以消除趋势项, 即存在 $(1-B)^2$ 项和小时, 天的季节差分后, 即存在滞后项 $(1-B), (1-B^{24})$ 的序列的自相关图和偏自相关图可以看出, 如图2, 图3所示, 对预处理后的序列分析其自相关图, 可以看到自相关系数基本上都落在随机区间, 表明处理后的序列已消除趋势项和季节项, 是一个平稳序列, 可以建立ARMA模型。

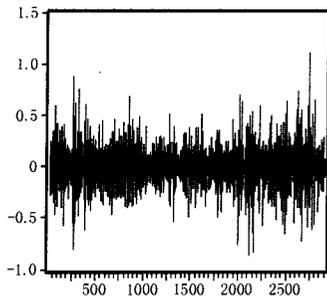


图2 预处理后的电价序列
Fig.2 Preprocessed price series

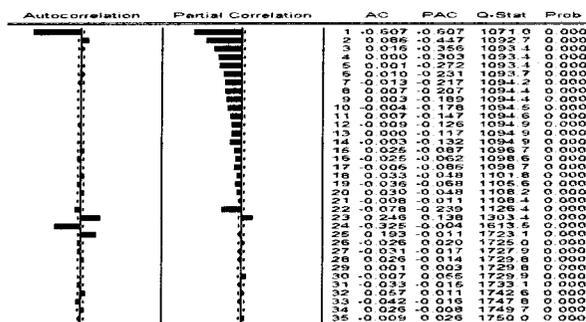


图3 预处理后序列相关图

Fig.3 Preprocessed price series correlogram

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	-0.541492	0.017449	-31.03240	0.0000
AR(2)	-0.475995	0.020378	-23.35870	0.0000
AR(3)	-0.411263	0.021873	-18.80250	0.0000
AR(4)	-0.356566	0.022131	-16.11130	0.0000
AR(5)	-0.274276	0.021512	-12.74977	0.0000
AR(6)	-0.176779	0.019742	-8.954652	0.0000
AR(7)	-0.105650	0.016511	-6.398764	0.0000
AR(23)	0.116546	0.015812	7.370795	0.0000
AR(24)	-0.379339	0.017849	-21.25215	0.0000
AR(47)	0.068566	0.016182	4.237262	0.0000
AR(48)	-0.384926	0.018954	-20.30864	0.0000
AR(71)	0.051092	0.015686	3.257215	0.0011
AR(72)	-0.358554	0.019703	-18.19797	0.0000
AR(96)	-0.301946	0.018765	-16.09092	0.0000
AR(118)	0.051232	0.013452	3.808523	0.0001
AR(120)	-0.269528	0.017612	-15.30396	0.0000
AR(144)	-0.164664	0.015810	-10.41533	0.0000
MA(1)	-1.034523	0.000111	-9342.981	0.0000
MA(22)	0.039103	0.000379	103.0867	0.0000
R-squared	0.824656	Mean dependent var	-6.76E-06	
Adjusted R-squared	0.823503	S.D. dependent var	0.164031	
S.E. of regression	0.068912	Akaike info criterion	-2.505108	
Sum squared resid	13.00235	Schwarz criterion	-2.464297	
Log likelihood	3472.292	F-statistic	715.3898	
Durbin-Watson stat	2.194866	Prob(F-statistic)	0.000000	

图4 参数估计

Fig.4 Parameter estimate

通过分析我们对图3所示序列建立ARMA模型, 采用普通最小二乘估计, 结果如图4所示。

参数估计后, 对ARMA模型的适合性进行检验, 及对模型的残差序列进行白噪声检验如图5所示, 可以看出残差序列的样本自相关系数基本都落入随机区间, 近似都等于零, 表明残差序列是纯随机的, 模型通过检验, 可以用来预测。

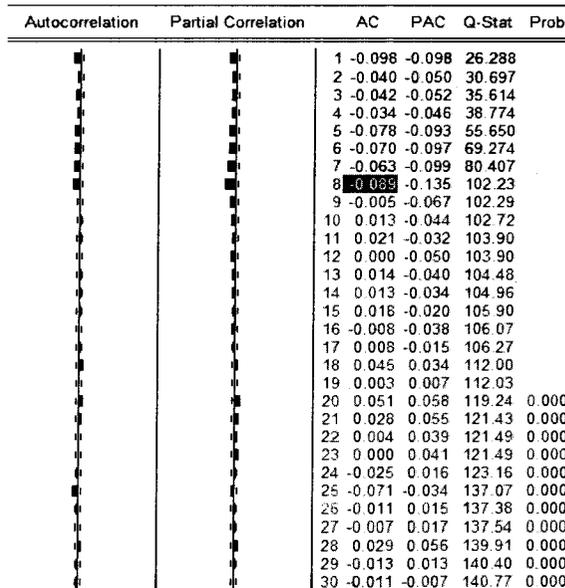


图5 残差相关图

Fig.5 Residual correlogram

从以上图中可以看出模型基本通过白噪声检验, 是比较合适的。先对模型进行试预测, 如图6所示, 将预测的结果与真实值进行比较, 由于其误差很小, 因此能够用来进行短期电价预测。预测结果图7所示。

同理, 对这段数据采用ARCH模型进行预测, 电价数据预处理过程同ARMA过程一样, 对电价序列进行趋势项和季节项的处理, 使其成为一个平稳的时间序列, 能够进行建立模型。

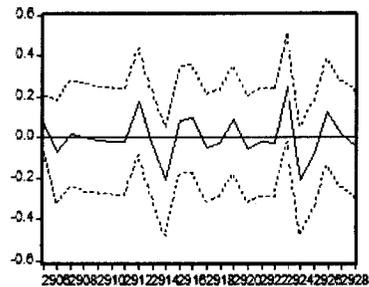


图6 试预测结果折线图

Fig.6 Test predicted results plot

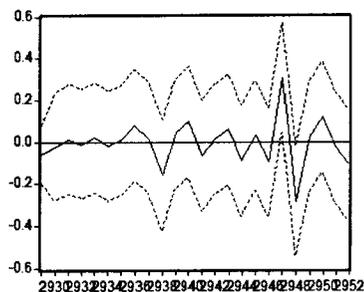


图7 预测结果折线图

Fig.7 Prediction results plot

以预处理后的历史电价作为因变量,考虑其自相关函数和偏自相关函数,建立如方程8所示模型。使用最小二乘参数估计,结果如图8所示。

从图中可以看出,基本上所有系数显著性检验对于95%的置信度均通过,而且模型的拟合优度达到0.83172,整体效果似乎不错,但对残差进行ARCH效应检验时,表明存在ARCH(2)效应。

Variable	Coefficient	Std. Error	t-Statistic	Prob
AR(1)	-0.060540	0.020650	-2.931700	0.0034
AR(2)	-0.023940	0.018185	-1.316452	0.1881
AR(3)	-0.101985	0.016959	-6.013702	0.0000
AR(4)	-0.082681	0.017247	-4.788235	0.0000
AR(23)	0.038023	0.015864	2.396727	0.0166
AR(24)	-0.451268	0.019266	-23.42246	0.0000
AR(48)	-0.448014	0.021299	-21.03492	0.0000
AR(72)	-0.521434	0.022353	-23.32769	0.0000
AR(96)	-0.364033	0.023088	-15.76727	0.0000
AR(119)	-0.056516	0.016145	-3.500609	0.0005
AR(120)	-0.311947	0.022622	-13.78957	0.0000
AR(143)	-0.098190	0.016254	-6.041091	0.0000
AR(144)	-0.183561	0.021172	-8.66967	0.0000
AR(168)	0.154943	0.019242	8.052497	0.0000
MA(1)	-1.718414	0.021631	-79.44397	0.0000
MA(2)	0.721255	0.021750	33.16161	0.0000
R-squared	0.832644	Mean dependent var	-8.30E-07	
Adjusted R-squared	0.831720	S.D. dependent var	0.163839	
S.E. of regression	0.067210	Akaike info criterion	-2.556155	
Sum squared resid	12.27315	Schwarz criterion	-2.521538	
Log likelihood	3508.986	F-statistic	901.1918	
Durbin-Watson stat	1.973581	Prob(F-statistic)	0.000000	

图8 参数估计

Fig.8 Parameter estimate

因此建立ARMA-ARCH模型,采用极大似然估计,结果如图9所示。

	Coefficient	Std. Error	z-Statistic	Prob
AR(1)	-0.035731	0.016285	-2.194090	0.0282
AR(2)	0.019032	0.015321	1.242251	0.2141
AR(3)	-0.065365	0.013985	-4.680464	0.0000
AR(4)	-0.044765	0.014761	-3.032656	0.0024
AR(23)	0.031101	0.012748	2.439609	0.0147
AR(24)	-0.482648	0.013795	-34.98699	0.0000
AR(48)	-0.469812	0.015309	-30.68932	0.0000
AR(72)	-0.506033	0.016154	-31.32461	0.0000
AR(96)	-0.412199	0.017010	-24.23210	0.0000
AR(119)	-0.050623	0.011078	-4.569732	0.0000
AR(120)	-0.390912	0.018036	-21.67372	0.0000
AR(143)	-0.073395	0.012758	-5.752922	0.0000
AR(144)	-0.234415	0.016684	-14.94566	0.0000
AR(168)	0.119764	0.013329	8.985211	0.0000
MA(1)	-1.846754	8.58E-08	-21526.162	0.0000
MA(2)	0.848196	8.25E-05	10284.44	0.0000

Variance Equation				
	C	Std. Error	z-Statistic	Prob
ARCH(1)	0.002887	8.33E-05	34.65343	0.0000
ARCH(1)	0.296111	0.021707	13.64108	0.0000
ARCH(2)	0.083995	0.014865	5.650504	0.0000

R-squared	0.842240	Mean dependent var	-8.30E-07	
Adjusted R-squared	0.841194	S.D. dependent var	0.163839	
S.E. of regression	0.065291	Akaike info criterion	-2.680932	
Sum squared resid	11.66944	Schwarz criterion	-2.639824	
Log likelihood	3682.494	F-statistic	804.3634	
Durbin-Watson stat	1.864335	Prob(F-statistic)	0.000000	

图9 参数估计

Fig.9 Parameter estimate

从图中可以看出,ARCH(2)的系数之和小于1,满足平稳条件。将该模型用于试预测,结果表明预测精度较好,可以用来进行短期预测。

根据以上模型的预测结果,由于本文仅仅考虑了历史电价这个因素对未来电价的影响,于是将上述两个模型的预测结果作为神经网络的输入层。在神经网络的应用中,由于BP网络是一种多层前馈型神经网络,其神经元的传递函数是S型函数,可以实现从输入到输出的任意非线性映射,应用十分广泛,因此本文也采用三层的BP神经网络。

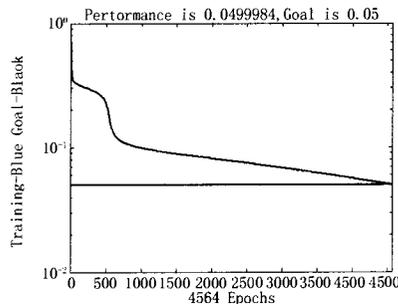


图10 神经网络训练图

Fig.10 Neural network training

分别把上述ARIMA和ARCH模型的预测结果作为神经网络的训练数据,在进行网络训练时,才用的能量函数为:

$$E = \frac{1}{2} \sum_{i=1}^m \|y_i - y_i'\|^2 \quad (13)$$

其中: y_i 表示实际电价, y_i' 表示网络训练的预测电价, m 表示样本个数。对网络参数进行不断修正,以使能量函数达到最小为原则,程序如下:

```
[Input,minp,maxp,Output,mint,maxt]=premnmx(inp,
outPut');
s=7;
net=newcf(minmax(Input),[s,1],{'radbas','tansig'},'traingdm');
net.trainParam.epochs=15000;
net.trainParam.goal=0.05;
net.trainParam.lr=0.05;
net.trainParam.mc=0.7;
net=train(net,Input,Output);
```

采用该模型对PJM电力市场2006年12月1日的电价进行预测,以绝对误差 σ 作为评价指标来衡量预测结果。

$$\sigma = (y_i' - y_i) / y_i \quad (14)$$

其中: y_i 表示实际值, y_i' 表示网络训练值。表1给

出了神经网络训练结果及其预测误差,图 10 给出了神经网络的训练图。

从表 1 可以看出,与真实值相比,其相对误差绝对值都在 10%以内,预测效果比较好。由于影响电价的因素很多,而该模型只考虑了历史电价这个因素,所以存在一定的局限性。

表 1 神经网络训练结果

Tab.1 Neural network training results

时段	1	2	3	4	5	6
预测值	-0.3809	-0.7311	0.0556	-0.0357	0.0195	-0.5356
真实值	0.0491	-0.1827	0.0344	-0.0115	0.0855	-0.1069
绝对误差	-8.756	3.0026	0.6171	2.1125	-0.772	4.0117
时段	7	8	9	10	11	12
预测值	0.0523	-0.0401	0.0832	-0.5767	0.6324	-0.0152
真实值	0.064	0.0335	0.0421	-0.184	0.1427	-0.0055
绝对误差	-0.1823	-2.1969	0.9769	2.1345	3.4326	1.761
时段	13	14	15	16	17	18
预测值	-0.5996	0.0585	0.0017	-0.4841	0.5303	0.4113
真实值	-0.0896	0.1076	-0.0057	-0.1431	0.1075	0.108
绝对误差	5.6928	-0.4564	-1.2986	2.3825	3.9346	2.8069
时段	19	20	21	22	23	24
预测值	-0.4841	-0.1778	-0.1187	0.7885	-0.4855	-0.4367
真实值	-0.2262	0.1791	-0.1723	0.2957	-0.1873	-0.0391
绝对误差	1.1402	-1.993	-0.3111	1.667	1.5925	10.176

4 结论

本文提出了一种基于时间序列的 ARIMA 和 ARCH 模型以及神经网络的组合模型来预测美国 PJM 电力市场未来 24 h 的日前电价,相对于单独采取时间序列方法或是神经网络模型来说,克服了单一方法所存在的局限性,是电价预测的一次小小的进步,取得了很好的效果。文章首先采用 ARIMA 模型对 PJM 电力市场 2006 年 8 到 11 月的历史电价数据进行模型分析,接受采用 ARCH 模型对这段电价建模进行分析,最后将这两个模型的预测结果作为 BP 神经网络的输入进行训练,网络的输出作为最后的预测结果。本文成功之处是综合运用 2 个时间序列模型和神经网络来预测电价,这一组合模型克服了单一方法的缺陷,预测结果良好,缺陷的地方是没有能把最后预测的结果转换成原始数据,这也是以后有待改进的地方。由于影响电价因素很多,本文仅考虑了历史数据,而且所取数据有限,因此预测结果存在一定的误差,但对日后的竞价策略能起到一定的指导作用,能够满足电力系统的电价预测要求。

参考文献

- [1] Contreras J, Espinola R, Nogales F J, et al. ARIMA Models to Predict Next Day Electricity Prices[J]. IEEE Trans on Power Systems, 2003, 18(3).
- [2] Pascual L, Romo J, Ruiz E. Bootstrap Prediction for Returns and Volatilities in GARCH Models[J]. Computational Statistic & Data Analysis, 2006, 50: 2293-2312.
- [3] Garcia R C, Contreras J A. GARCH Forecasting Model to Predict Day Ahead Electricity Prices[J]. IEEE Trans on Power Systems, 2005, 20(2).
- [4] Erdogdu E. Electricity Demand Analysis Using Cointegration and ARIMA Modeling[J]. Energy Policy, 2007, 35: 1129-1146.
- [5] Conejo A J, Plazas M A, Espinola R, et al. Day Ahead Electricity Price Forecasting Using the Wavelet Transform and ARIMA Models[J]. IEEE Trans on Power Systems, 2005, 20(2).
- [6] Kosater P, Mosler K. Can Markov Regimes Switching Models Improve Power Price Forecasts? Evidence from German Daily Power Prices[J]. Applied Energy, 2006, 83: 943-958.
- [7] Rivals I, Personnaz L. Construction of Confidence Intervals Neural Networks Based on Least Squares Estimation[J]. Neural Networks, 2000, 13: 463-484.
- [8] Amjady N. Day-ahead Price Forecasting of Electricity Markets by a New Fuzzy Neural Network[J]. IEEE Trans on Power Systems, 2006, 21(2).
- [9] Khotanzad A, Zhou En-wang, Elragal H. A Neuro Fuzzy Approach to Short Term Load Forecasting in a Price Sensitive Environment[J]. IEEE Trans on Power Systems, 2002, 17(4).
- [10] 张显, 王锡凡. 短期电价预测综述[J]. 电力系统自动化, 2006, 30(3): 96-105.
ZHANG Xian, WANG Xi-fan. Review of the Short-term Electricity Price Forecasting[J]. Automation of Electric Power Systems, 2006, 30(3): 96-105.
- [11] 谢培元, 曾次玲. 基于神经网络的电价预测[J]. 研究与试验, 2004, 24(2).
- [12] Khotanzad A, Zhou En-wang, Elragal H. A Neuro Fuzzy Approach to Short Term Load Forecasting in a Price Sensitive Environment[J]. IEEE Trans on Power Systems, 2002, 17(4).
- [13] ZHANG Bai-ling, DONG Zhao-yang. An Adaptive Neural Wavelet Model for Short Term Load Forecasting[J]. Electric Power Systems Research, 2001, 59: 121-129.

收稿日期: 2007-06-18; 修回日期: 2007-08-04

作者简介:

胡峰(1983-), 男, 硕士研究生, 主要研究方向为电力市场; E-mail: hufeng1360325304@163.com

彭力(1967-), 男, 博士, 教授, 主要研究方向为智能控制与计算机仿真。