

美元/欧元汇率的趋势与波动分析及区间预测

陈 静, 李星野

(上海理工大学 管理学院, 上海 200093)

摘要: 对美元/欧元汇率进行趋势与波动分析并作出区间预测。利用 BP 神经网络提取趋势, 对残差分别运用自回归移动平均模型和广义自回归条件异方差模型分析波动性, 将趋势与波动性结合给出区间预测。对 2001 年 7 月至 2017 年 10 月美元/欧元汇率的研究发现, BP 神经网络具有很好的非线性刻画能力, 但只有合适的预测精度才能得出较好的预测区间, 同时也发现, 广义自回归条件异方差模型对波动性的分析效果优于自回归移动平均模型。因此, BP 神经网络模型与广义自回归条件异方差模型的组合模型 (BP-GARCH 模型) 更适合时间序列的中长期区间预测。通过调节 BP 神经网络的参数、误差及预测精度提高组合模型的精度。

关键词: BP 神经网络; GARCH 模型; 组合模型; 区间预测

中图分类号: F 832.6 **文献标志码:** A

Trends and Volatility Analysis and the Interval Forecast of USD/EUR Exchange Rate

CHEN Jing, LI Xingye

(Business School, University of Shanghai for Science and Technology, Shanghai 200093, China)

Abstract: Analyzing the trend and fluctuation of time series and making the interval forecast of USD/EUR exchange rate. It is of great value to improve the current accuracy of the forecasting method based on the trend. A BP neural network was used to extract the trend and the volatility was analyzed by using a auto-regressive moving average model and a generalized auto-regressive conditional heteroscedasticity model. Finally, the trend and volatility were combined to give the forecast. By the study of the USD/EUR exchange rate from July 2001 to October 2017, it is found that the BP neural network has a good non-linear characterization ability, but only the appropriate prediction accuracy can lead to a better prediction interval and the regression conditional heteroscedasticity model is superior to the auto-regressive moving average model for the analysis of volatility. The accuracy of the combined model can be improved by adjusting the parameters, errors and prediction accuracy of the BP neural network.

Keywords: BP neural network; GARCH model; combination model; interval forecast

汇率是一个国家的货币对外价格的表现形式, 是一种相对价格。受到很多原因的影响, 除了经济原因, 还有政治原因。如不同利率的差异、各国的通货膨胀程度、全球的金融环境等^[1]。这就使得汇率并不容易通过几个因素就解释清楚, 本文选取时间序列分析方法, 研究美元/欧元的每日收盘价, 希望能够研究出这一序列的趋势和波动性。

过去几年, 较多领域的预测模型仍采用单个模型, 如自回归移动平均模型、BP 神经网络(反向传播神经网络)、RBF 径向基网络(即径向基函数神经网络)、ARCH 模型(自回归条件异方差模型)等。许少强等^[2]用自回归移动平均模型提取出欧元/美元以及日元/美元汇率的走势, 对两种汇率差分后建立 ARMA 模型(自回归移动平均模型)提取其走势, 对人民币/美元汇率进行了中长期的预测。由于现实中的时间序列一般均为非平稳时间序列, 越来越多的学者开始研究人工神经网络模型。朱家荣等^[3]用 RBF 神经网络拟合人民币/美元汇率这一时间序列, 较好地刻画出了该序列的趋势特性。经过多领域的综合研究发现, RBF 神经网络的预测误差较大, BP 神经网络存在收敛速度慢、精确度不高、容易限于局部极小值等一系列问题^[4-5]。为了提高 BP 神经网络预测模型对时间序列的预测精度, 惠晓峰等^[6]在遗传算法的基础上, 结合递归预测方法, 提出了基于实数编码的 GA-BP 神经网络预测模型, 有效地提高了模型的预测精度。为了弥补 BP 神经网络在连接权值和阈值上的不足, 侯越等^[7]在萤火虫算法和 BP 神经网络的基础上, 提出了用萤火虫算法优化 BP 神经网络, 并将该算法应用到 Duffing 系统产生的混沌时间序列, 得到的网络初始权值和阈值远远优于原模型, 这说明优化后的算法准确性更高。

真实的金融序列并非同方差, Engle 在 1982 年提出 ARCH 模型^[8-9], 可以刻画随时间变化的条件异方差。Bollerslev 在此前提下提出了 GARCH 模型(广义的 ARCH 模型)^[10], 不仅可以反映条件异方差, 而且能体现真实数据的长期记忆性。

随着研究的不断深入, 线性与非线性模型的结合成为新的研究方向。Kristjanpoller 等^[11]提出将自回归条件异方差模型与人工神经网络组合, 运用 GARCH(1, 1)模型对石油现货价格进行分析, 将分析结果作为人工神经网络的输入, 进而发现

这一模型相比于调整异方差的均方误差模型, 将波动性的预测精度提高了 30%。

本文选取美元/欧元每日汇率的收盘价作为研究数据, 运用 BP 神经网络模型拟合序列的总体趋势, 在此基础上, 分别构建自回归移动平均模型和广义的自回归条件异方差模型, 与 BP 网络模型线性叠加, 通过一定的参数优化, 得到了较好的时间序列分析模型。

1 预测原理及方法

1.1 BP 神经网络

BP 算法是一种按照误差逆向传播训练的多层前馈神经网络^[12-16]。图 1 给出了 3 层 BP 网络模型。图中, ξ_k 表示输入, V_j 表示隐含层, O_i 表示输出。 w_{jk} 表示输入 k 与隐含层 V_j 的连接权值, W_{ij} 是隐含层 V_j 与输出 O_i 之间的连接权值, $\omega = \{W, w\}$ 中存储了全部的连接权值。对于特定的输入模式 μ , 隐含层 V_j 的输入

$$H_j^\mu = \sum_{k=1}^K \omega_{jk} \xi_k^\mu \quad (1)$$

输出

$$V_j^\mu = g_1(H_j^\mu) = g_1\left(\sum_{k=1}^K \omega_{jk} \xi_k^\mu\right) \quad (2)$$

输出 O_i 的输入

$$H_i^\mu = \sum_{j=1}^J W_{ij} V_j^\mu = \sum_{j=1}^J W_{ij} g_1\left(\sum_{k=1}^K \omega_{jk} \xi_k^\mu\right) \quad (3)$$

最终输出

$$O_i^\mu = g_2(H_i^\mu) = g_2\left[\sum_{j=1}^J W_{ij} g_1\left(\sum_{k=1}^K \omega_{jk} \xi_k^\mu\right)\right] \quad (4)$$

对应于任意的输入模式 μ 和输出 i , 在线误差函数

$$E^\mu(\omega) = 0.5(\xi_i^\mu - O_i^\mu)^2 = 0.5\left\{\xi_i^\mu - g_2\left[\sum_{j=1}^J W_{ij} g_1\left(\sum_{k=1}^K \omega_{jk} \xi_k^\mu\right)\right]\right\}^2 \quad (5)$$

对输出 O_i , 总的误差函数

$$E(\omega) = \sum_{\mu=1}^P E^\mu(\omega) = 0.5 \sum_{\mu=1}^P (\xi_i^\mu - O_i^\mu)^2 \quad (6)$$

式中: ξ_i^μ 表示模式 μ 所对应输出 O_i 的期望值; μ 表示不同的输入模式; P 表示输入模式的个数 ($\mu = 1, 2, \dots, P$); g_1 和 g_2 代表隐含层和输出层的激活函数。




图1 BP神经网络的结构图
Fig.1 BP neural network structure diagram

1.2 ARMA 模型

ARMA 模型(自回归移动平均模型)^[17-18]可描述为

$$y(n) = \varphi_1 y(n-1) + \varphi_2 y(n-2) + \cdots + \varphi_p y(n-p) + \mu(n) + \theta_1 \mu(n-1) + \theta_2 \mu(n-2) + \cdots + \theta_q \mu(n-q) \quad (7)$$

式中: $y(n)$ 表示时间序列在 n 时刻的值; $\varphi_1, \varphi_2, \varphi_3, \cdots, \varphi_p$ 为自回归模型的系数; p 为自回归模型阶数; $\theta_1, \theta_2, \cdots, \theta_q$ 为 q 阶移动平均模型的系数; $\mu(n)$ 为白噪声过程,均值为0,方差为 σ^2 。

递推可得^[19]

$$y(n) = \sum_{j=0}^{\infty} G_j \mu(n-j) \quad (8)$$

式中, G_j 为格林系数。

时间序列的波动方差就是 $\sum_{j=0}^{l-1} G_j^2 \sigma^2$,如果序列未来 l 期的预测值是 $\hat{y}(n+l)$,那么, $y(n+l)$ 的置信区间(置信水平为 $1-\alpha$)为

$$\left[\hat{y}(n+l) - u_{\alpha/2} \left(\sum_{j=0}^{l-1} G_j^2 \right)^{1/2} \sigma, \hat{y}(n+l) + u_{\alpha/2} \left(\sum_{j=0}^{l-1} G_j^2 \right)^{1/2} \sigma \right] \quad (9)$$

式中, $u_{\alpha/2}$ 为标准正态分布的上 $\alpha/2$ 临界值。

1.3 GARCH 模型

Bolloserslev 提出的 GARCH 模型,主要是针对金融序列的回归以及波动性分析^[20]。GARCH 模型的构成可表示为

$$y_t = C + \varepsilon_t \quad (10)$$

$$\sigma_t^2 = K + \sum_{i=1}^P G_i \sigma_{t-i}^2 + \sum_{j=1}^Q A_j \varepsilon_{t-j}^2 \quad (11)$$

$$K > 0, \sum_{i=1}^P G_i + \sum_{j=1}^Q A_j < 1$$
$$G_i \geq 0, i = 1, 2, \cdots, P, \quad A_j \geq 0, j = 1, 2, \cdots, Q$$

式中: y_t 为收益率序列; C 与 K 为常数; ε_t 为均值; σ_t^2 为收益率序列的方差; G_i 与 A_j 为权重系数。

式(10)为条件均值方程,式(11)为条件方差方程。

2 实证分析

研究数据为2001年7月至2017年10月期间的美元/欧元的每日收盘价,数据共计6000个,如图2所示。




图2 美元/欧元汇率2001年7月至2017年10月的历史数据
Fig.2 USD/EUR exchange rate historical data from July 2001 to October 2017

2.1 BP 模型建立

时间序列通常可以表示为 $x(t), t = 1, 2, \cdots, n$, 第一步需要根据选定的嵌入维数 m 和时间延迟 τ 重构相空间^[21]。

$$\{Y(t)|Y(t)=[x(t), x(t+\tau), \cdots, x(t+(m-1)\tau)], t = 0, 1, 2, \cdots, n-(m-1)\tau\} \quad (12)$$

$Y(t)$ 是时间序列在 t 时刻的值,且从嵌入定理^[22-23]可知,存在光滑的映射 $f: \mathbb{R}^n \rightarrow \mathbb{R}$ 符合:

$$x(t+m\tau) = f(Y(t)) = f(x(t), x(t+\tau), \cdots, x(t+(m-1)\tau)) \quad (13)$$

实验结果通过均方误差 MSE 和相对误差 $Perr$ 来分析。

$$MSE = \frac{1}{N} \sum_{i=0}^N |x(t+1) - \hat{x}(t+1)|^2 \quad (14)$$

$$Perr = \frac{1}{N} \sum_{i=0}^N |x(t+1) - \hat{x}(t+1)|^2 \bigg/ \sum_{i=0}^N x^2(t+1) \quad (15)$$

式中: $x(t)$ 为真实值; $\hat{x}(t)$ 为其对应的预测值; N 为序列的个数。

2.2 BP神经网络实证分析

2.2.1 参数确定

以汇率数据的前 5 000 个为网络的训练数据, 用其后的 1 000 个数据测试训练的结果。这一时间

序列自相关性较强, 为了验证选择不同的输入节点个数的模型结果, 将其对应的均方误差图和平




图 3 不同隐含层节点数的均方误差图

Fig.3 Mean squared error plots for the number of nodes in different hidden layers

从图 3 可知, 输入层节点数为 17 时, 预测的误差最小, 拟合效果良好, 所以, 初步将输入节点个数 n 选为 17, 时间延迟 $\tau = 1$ 。隐含层的节点个数一般根据经验决定, 通常通过以下几种方法来确定: a. $n_l = \sqrt{nt}$; b. $n_l = \sqrt{n+t} + \alpha$; c. $n_l = \log_2 n$ 。 n 是输入节点的个数, t 是输出节点的个数, 从经验方法出发, 隐含层节点的个数可以初步列为 4 或

5。另外, 当隐含层节点的个数选为 3 时, 误差都最小。不过, 为了防止模型过拟合, 本文通过选取不同的隐含层节点个数, 构建不同参数的模型, 对比验证得出结论: 只有在隐含层的节点个数是 3 时, 才能得出比较好的模型。该模型的拟合结果如图 4 所示。




图 4 2017 年 7 月至 2017 年 10 月的美元/欧元汇率 BP 神经网络 (17-3-1) 预测图

Fig.4 BP neural network (17-3-1) forecast graph of USD/EUR exchange rate from July 2017 to October 2017

该模型的相对误差是 $1.595\,3\times10^{-5}$ ，均方误差是 $1.199\,5\times10^{-5}$ 。从图4可知，BP神经模型(17-3-1)的预测性能良好，将BP神经网络的拟合结果输入到下一个模型，再将2个模型进行线性叠加，得到2个模型的组合预测区间。但是，实验发现，输入节点定为17时，组合区间的准确性并不理想，所以，要优化模型的输入层节点个数、隐含层节点个数和精度设置。

2.2.2 参数优化

单个模型的预测精度高并不代表组合模型的效果就一定好，所以，需要找一个平衡点，既要避免单个模型精度过高导致过拟合，又要避免组合模型的效果不尽人意。通过适当地增大BP神经网络的预测精度，提高了组合模型的整体效果，模型结果最终确定为50-7-1，得到BP神经网络的预测结果如图5所示。




图5 2017年7月至2017年10月的美元/欧元汇率BP神经网络(50-7-1)预测图

Fig.5 BP neural network (50-7-1) forecast graph of USD/EUR exchange rate from July 2017 to October 2017

从图5可以看出，模型对原序列的拟合效果较好。将该模型的残差序列 $\{c(x)\}$ 输入到ARMA以及GARCH模型，作为新的输入数据。

2.3 BP-ARMA 模型实证分析

2.3.1 ARMA 模型实例分析

首先对残差时间序列 $c\{x\}$ 进行单位根检验，

结果显示 $c\{x\}$ 已经平稳。通过自相关系数(AC)和偏自相关系数(PAC)以及AIC(Akaike information criterion, 赤池信息准则)、BIC(Bayesian information criterion, 贝叶斯信息准则)的值来确定ARMA模型的参数 p 与 q ，序列 $\{c(x)\}$ 的自相关系数以及偏自相关系数如图6所示。




图6 残差序列 $\{c(x)\}$ 的自相关图

Fig.6 Autocorrelation diagram of residual sequence $\{c(x)\}$

图 6 中, 概率为 Q 统计量取值大于该样本计算的 Q 值的概率。从 AC 可以看出, 序列 $c\{x\}$ 的自相关系数 2 阶拖尾, 偏自相关系数 1 阶结尾, 将参数确定为 $p=1, q=2$ 。模型估计结果如表 1 所示。

表 1 ARMA(1, 2)模型估计结果
Tab.1 Estimation results of ARMA (1, 2) model

变量	系数	标准差	t 检验	概率
C	-0.001 180	0.000 168	7.011 840	0
AR(1)	0.332 139	0.341 123	0.973 663	0.330 5
一阶移动平均模型	0.011 350	0.340 073	0.033 376	0.973 4
二阶移动平均模型	-0.028 523	0.121 087	-0.235 556	0.813 8
方差估计值	1.14×10^{-5}	3.24×10^{-7}	35.162 680	0
决定系数	0.111 461	均值		0.001 177
调整后的决定系数	0.107 490	标准差		0.003 583
回归的标准误差	0.003 385	赤池信息准则		-8.533 042
残差平方和	0.010 257	贝叶斯信息准则		-8.506 362
对数似然函数值	3 844.869	汉南-奎因准则		-8.522 850
F 检验	28.067 82	D.W 检验		1.992 171
概率 (F 检验)	0			

对 ARMA(1, 2)模型进行残差检验, 得到自相关和偏自相关系数, 如图 7 所示。

从图 7 可以看出, 残差序列的自相关、偏自相关系数都处于 95% 的置信区间之内, 且自相关系数的概率值均高于检验水平 0.05, 因此, 得出结论: ARMA(1, 2)模型的残差序列不存在自相关性。可得 ARMA(1, 2)表达式为

$$y_t = 0.332\ 14y_{t-1} + \varepsilon_t -$$
$$0.011\ 35\varepsilon_{t-1} - 0.028\ 52\varepsilon_{t-2} + 0.001\ 18$$

(16)

利用 ARMA(1, 2)对 $\{c(x)\}$ 序列前 900 个数据进行拟合, 对后 100 个数据进行区间预测, 可得置信度为 95% 的置信区间, 如图 8 所示。

从图 8 可以看出, 大部分的真实值均落在 ARMA(1, 2)模型的预测区间内, 这验证了 ARMA 模型分析时间序列波动的有效性, 而有超过 5% 的点落在预测区间外, 同时也说明自回归移动平均模型在波动性分析方面的精度还不够。

2.3.2 线性叠加

利用 ARMA(1, 2)模型预测 BP 神经网络模型的残差, 将 ARMA(1, 2)对 $c\{x\}$ 序列的预测结果与 BP 神经网络的预测结果线性叠加, 可得到美元/欧元汇率在 5 901~6 000 这一时间段的预测区间, 如图 9 所示。

从图 9 可以看出, 除了误差允许范围内的少部分真实值落在预测区间外, 其余的真实值均落在区间内, 且与真实数据的趋势也保持一致。

2.4 BP-GARCH 模型实证分析

2.4.1 GARCH 模型实例分析

前面已经证明序列 $\{c(x)\}$ 具有平稳性。用 ARCH-LM 方法验证出该序列具有高阶的 ARCH 效应, 那么, 采取 GARCH 模型就可以很好地消除该序列的条件异方差特性。依据最小 AIC 原则, 构建模型 GARCH(1, 1), 模型的参数如表 2 所示。GARCH(1, 1)的表达式为

$$y_t = y_{t-1} + \varepsilon_t - 0.745\ 1\varepsilon_{t-1} -$$
$$0.230\ 4\varepsilon_{t-2} + 0.000\ 247$$

(17)

$$\sigma_t^2 = 0.970\ 6\sigma_{t-1}^2 + 0.027\ 90\varepsilon_{t-1}^2$$

(18)

利用该模型拟合前 900 个数据, 得到后 100 个




图 7 残差序列相关图

Fig.7 Correlation diagram of residual sequence




图 8 残差序列 $c\{x\}$ 95% 的预测区间

Fig.8 95% prediction interval of residual sequence $c\{x\}$




图 9 BP-ARMA 组合模型 95% 的预测区间

Fig.9 95% prediction interval by the BP-ARMA combination model

表 2 GARCH (1, 1) 模型估计结果

Tab.2 Estimation results by the GARCH (1, 1) model

变量	系数	标准差	z 检验	概率
C	0.000 447	0.236 992	0.001 885	0.998 5
$AR(1)$	1.000 000	2.28×10^{-5}	43 896.20	0
$MA(1)$	-0.745 112	0.036 083	-20.649 67	0
$MA(2)$	-0.230 430	0.034 788	-6.623 745	0
C	3.53×10^{-8}	1.60×10^{-8}	2.209 804	0.027 1
残差序列一阶滞后的平方	0.027 892	0.009 361	2.979 523	0.002 9
一价 GARCH 模型	0.970 574	0.008 348	116.269 1	0
t 分布自由度参数	4.595 803	0.631 181	7.281 270	0
决定系数	0.099 214	均值		0.001 177
调整后的决定系数	0.096 198	标准差		0.003 583
回归的标准误差	0.003 407	赤池信息准则		-8.806 638
残差平方和	0.010 399	贝叶斯信息准则		-8.763 950
对数似然函数值	3 970.987	汉南-奎因准则		-8.763 950
D.W 检验	1.992 171			

的拟合结果，并预测其波动区间，得到置信度为 95% 的置信区间以及其预测方差，如图 10 所示。

从图 10 可以看出，序列全部的真实值都处在置信区间内，方差也随着迭代步数的增加而变大，整体的预测效果良好。

2.4.2 线性叠加

将 BP 神经网络和 GARCH(1, 1)模型的预测结果进行线性叠加，就可以得到美元/欧元汇率序列置信水平为 95% 预测区间，如图 11 所示。

从图 11 可知，只有 4 个真实值不在置信区间之内，2 种模型组合的效果较好。

2.5 模型对比

从图 9 与图 11 的结果可以看出，BP 与 GARCH 模型的组合相比于 BP 与 ARMA 模型的组合，区间估计更准确，只有极少数误差允许范围内的时间节点的真实值超出预测区间，而 BP-ARMA 的组合模型在 100 个时间节点当中有超过 10 个时间




图 10 GARCH (1 , 1) 模型对残差序列 { c (x) } 的区间预测

Fig.10 Interval prediction of residual sequence {c(x)} by the GARCH (1, 1) model




图 11 BP-GARCH (1 , 1) 模型对美元/欧元汇率 95% 的预测区间

Fig.11 95% interval forecast of USD/EUR exchange rate by the BP-GARCH (1, 1) model

节点的真实值超出了预测区间, 说明 BP-GARCH 模型要优于 BP-ARMA 模型, 更适合对金融时间序列进行趋势与波动性分析。

3 总结与展望

将 BP 神经网络分别与 ARMA, GARCH 模型进行组合, 对比分析近几年美元/欧元汇率的趋势与波动性, 结果显示, BP 神经网络的非线性映射能力较强, 可以准确地刻画时间序列的趋势。通过适当地增大 BP 神经网络模型的误差来提高组合模型的预测效果, 构建出一结构为 50-7-1 的 BP 神经网络模型, 接着采用 ARMA(1, 2) 与 GARCH(1, 1) 模型提取 BP 神经网络的拟合结果的波动信息, 最后结合 BP 神经网络模型的趋势特性, 得出美元/欧元汇率的拟合趋势以及置信水平为 95% 的预测区间。比较 BP-ARMA(1, 2) 与 BP-GARCH(1, 1) 这 2 个模型的预测效果, 可以得

出: BP-GARCH(1, 1) 模型的预测效果比单一的 BP 神经网络模型好, 也比 BP-ARMA(1, 2) 组合模型的效果更好。

参考文献:

- [1] 聂淑媛. 时间序列分析的早期发展[D]. 西安: 西北大学, 2012.
- [2] 许少强, 李亚敏. 参考“一篮子”货币的人民币汇率预测——基于 ARMA 模型的实证方法[J]. 世界经济文汇, 2007(3): 30-40.
- [3] 朱家荣, 梅索, 赵东方. 基于 RBF 网络的汇率短期预测[J]. 统计与决策, 2008(17): 120-121.
- [4] 李友坤. BP 神经网络的研究分析及改进应用[D]. 淮南: 安徽理工大学, 2012.
- [5] 王文剑. 一种输入驱动的 BP 网络高效学习算法[J]. 系统工程理论与实践, 2000, 20(1): 99-101.
- [6] 惠晓峰, 胡运权, 胡伟. 基于遗传算法的 BP 神经网络在汇率预测中的应用研究[J]. 数量经济技术经济研究, 2002, 19(2): 80-83.
- [7] 侯越, 赵贺, 路小娟. 基于萤火虫优化的 BP 神经网络算

- 法研究[J]. [兰州交通大学学报](#), 2013, 32(6): 24–27.
- [8] CRYER J D, CHAN K S. 时间序列分析及应用[M]. 潘红宇, 译. 北京: 机械工业出版社, 2011.
- [9] ENGLE R F. Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom inflation[J]. [Econometrica](#), 1982, 50(4): 987–1007.
- [10] BOLLERSLEV T. Generalized autoregressive conditional heteroskedasticity[J]. [Journal of Econometrics](#), 1986, 31(3): 307–327.
- [11] KRISTJANPOLLER W, MINUTOLO M C. Forecasting volatility of oil price using an artificial neural network-GARCH model[J]. [Expert Systems with Applications](#), 2016, 65: 233–241.
- [12] 苏高利, 邓芳萍. 论基于 MATLAB 语言的 BP 神经网络的改进算法[J]. [科技通报](#), 2003, 19(2): 130–135.
- [13] 胡雪棉, 赵国浩. 基于 Matlab 的 BP 神经网络煤炭需求预测模型[J]. [中国管理科学](#), 2008, 16(S1): 521–525.
- [14] 熊志斌. 基于 ARIMA 与神经网络集成的 GDP 时间序列预测研究[J]. [数理统计与管理](#), 2011, 30(2): 306–314.
- [15] 盛仲飙. BP 神经网络原理及 MATLAB 仿真[J]. [渭南师范学院学报](#), 2008, 23(5): 65–67.
- [16] 司昕. 预测方法中的神经网络模型[J]. [预测](#), 1998(2): 32–35.
- [17] 黄俊, 周猛, 王俊海. ARMA 模型在我国能源消费预测中的应用[J]. [统计与决策](#), 2004(12): 49–50.
- [18] 李瑞莹, 康锐. 基于 ARMA 模型的故障率预测方法研究[J]. [系统工程与电子技术](#), 2008, 30(8): 1588–1591.
- [19] 陈志荣, 吴峻. ARMA 模型参数估计的格林函数法[J]. [天津大学学报](#), 1986(4): 45–49.
- [20] 王佳妮, 李文浩. GARCH 模型能否提供好的波动率预测[J]. [数量经济技术经济研究](#), 2005, 22(6): 74–87.
- [21] 王海燕, 盛昭瀚. 混沌时间序列相空间重构参数的选取方法[J]. [东南大学学报\(自然科学版\)](#), 2000, 30(5): 113–117.
- [22] PACKARD N H, CRUTCHFIELD J P, FARMER J D, et al. Geometry from a time series[J]. [Physical Review Letters](#), 1980, 45(9): 712–716.
- [23] SMALE S. Dynamical systems and turbulence[J]. [Turbulence Seminar](#), 1977, 615: 48–70.

(编辑: 石 磨)