

# 基于非线性时间序列的预测模型检验与优化的研究

单 伟, 何 群

(燕山大学电气工程学院, 河北秦皇岛 066004)

**摘 要:** 模型的适用性检验和参数优化是系统建模的最关键环节, 对于预测模型的适用性检验, 常采用残差方差图、最小信息准则和 AIC 准则等方法, 存在计算量大、准确性低、模型不唯一等缺点. 本文给出采用自相关系数和偏自相关系数的拖尾先对 ARIMA 模型检验, 再对其进行 F 适用性检验, 克服了由于观测样本的长度是有限的, 偏相关的估计存在误差, 拖尾时不能为 ARMA 定阶的缺陷, 并采用具有超线性收敛性等诸多优点的变尺度法对模型参数进行了优化, 得到了较为精确的、单一 AIRMA 模型, 该方法可应用于网络流量模型的适用性检验和模型优化, 为网络流量的预测、异常检测和服务器负载预测的应用奠定了坚实的基础.

**关键词:** 非线性; 时间序列; 适用性检验; 自回归求和滑动平均模型

**中图分类号:** TP393 **文献标识码:** A **文章编号:** 0372-2112 (2008) 12-2485-05

## Research of the Optimizing and Testing of Forecasting Model Based on the Non-linear Time Series

SHAN Wei, HE Qun

(Electric Engineering College, Yanshan University, Qinhuangdao, Hebei 066004, China)

**Abstract:** The adaptability testing of model and the optimization of model parameter are the most critical part in system modeling. Residual variance plot, minimum information criteria and AIC criteria are usually adopted in the adaptability testing of forecasting model, which includes disadvantages of big amount of calculating, low veracity and model is not the only. To adopt the trailing of auto correlation coefficients and partial correlation coefficients to test the ARMA model and then through the F adaptability testing, the disadvantages that the observation sample length is limited, estimation of the partial correlation has error and ARMA model order can not be determined when trailing have been overcome, and then optimized the model parameters by means of scale transformation which have many of the advantages such as ultra linear convergence and so on, thus the haploid ARMA model with higher veracity can be gained, which is a convincing method of network traffic model adaptability testing and model optimizing and established a stable foundation of the application of network traffic forecasting, abnormality testing and server loading forecast.

**Key words:** nonr linear; time series; adaptability testing; ARIMA

### 1 引言

时间序列分析广泛应用于数据流的预测<sup>[1~3]</sup>、气象预报、地球物理和卫星通信等领域, 设计和建立一个合理的预测模型对系统的预测与分析都是十分重要. 由于网络数据的非平稳性和不可预知因素的影响决定了应采用非线性时间序列建模方法来分析、预测. 系统建模的内容包括数据的检验与预处理、模型参数的估计、模型的适用性检验等问题, 而模型的适用性检验和模型参数优化则是系统建模的最关键环节.

ARIMA(Autoregressive integrated moving average) 模型的建模, 就是对观测所得的时间序列 $\{y(t)\}$ 经过预处理后, 拟合出适用的 ARMA( $p, q$ ). 不言而喻, 这是时序

方法的关键, 因为任何实际应用的成功与否都取决于所用模型的正确与否. 对于预测模型的适用性检验, 常采用残差方差图、最小信息准则、AIC(An information criterion) 准则和利用自相关系数与偏自相关系数的拖尾或截尾等方法, 存在计算量大、准确性低、模型不唯一等缺点<sup>[4]</sup>.

近年来, 许多学者在建模方面进行了大量的研究, 但是这些研究都是建立在传统的适用性检验方法的基础上, 虽然在一定程度上提高了定阶精度, 但都具有其局限性. 一些学者采用了神经网络、遗传算法等方法用于模型定阶, 但最终还是采用传统的定阶方法或定阶过程中仍采用传统参数估计方法<sup>[4]</sup>. 在时间序列分析应用方面, 大都采用残差方差图、AIC 准则和利用自相关系

数与偏自相关系数的拖尾或截尾等方法对模型定阶,并以此为基础进行数据预报和异常检测<sup>[5,6]</sup>. 本文给出采用自相关系数和偏自相关系数的拖尾先对 ARIMA 模型检验,再对其进行 F 适用性检验,克服了由于观测样本的长度是有限的,偏相关的估计存在误差,拖尾时不能为 ARMA 定阶的缺陷,再通过正规的 F 统计检验,并采用变尺度法优化模型参数,得到较为精确的、单一 AIRMA 模型. 该方法可应用于网络流量模型的适用性检验和模型优化,为网络流量的预测、异常检测和服务器负载预测的应用奠定了坚实的基础.

## 2 ARIMA 模型的建立

ARMA 模型的平稳性反映了时间序列的一类时间不变性质,对进行统计推断来说,某些时候是必要的条件,然而,实际时间序列数据常显示出时间趋势(诸如缓慢地增加)或循环特征,它们已不再满足平稳 ARMA 模型的要求,消除这些不平稳成分的通常做法是对数据作预处理,对于消除趋势性和季节性来说,取差分(如果必要,可作多次差分)是方便有效地方法. 在去掉时间趋势后,我们能够用平稳 ARMA 模型来建模这个新的保留序列,由于原始序列是差分序列地结合,我们称它为自回归和滑动平均 ARIMA 过程.

具有如下结构的模型称为 ARIMA 模型,简称为 ARIMA( $p, d, q$ ) 模型.

$$\begin{cases} \Phi(b) \nabla^d y(t) = \Theta(b) \varepsilon(t), \varepsilon(t) = \varepsilon \\ E(\varepsilon) = 0, \text{Var}(\varepsilon) = \sigma_\varepsilon^2, E(\varepsilon_s, \varepsilon_t) = 0, s \neq t \\ E[y(s) \varepsilon(t)] = 0, \forall s < t \end{cases} \quad (1)$$

式(1)中:

$$\nabla^d y(t) = \sum_{i=1}^d (-1)^i c_d^i y(t-i), c_d^i = \frac{d!}{i! (d-i)!}$$

$\Phi(b) = 1 - \varphi_1 b - \varphi_2 b^2 - \dots - \varphi_p b^p$ , 为平稳可逆 ARMA( $p, q$ ) 模型的自回归系数多项式.

$\Theta(b) = 1 - \theta_1 b - \theta_2 b^2 - \dots - \theta_q b^q$ , 为平稳可逆 ARMA( $p, q$ ) 模型的移动平滑系数多项式.

式(1)可简化为:

$$\nabla^d y(t) = \frac{\Theta(b)}{\Phi(b)} \varepsilon \quad (2)$$

式中,  $\{\varepsilon_t\}$  为零均值白噪声序列.

由式(2)显而易见, ARIMA 模型的实质就是差分运算与 ARMA 模型的组合,这一关系意义重大,这说明任何非平稳序列只要通过适当阶数的差分实现差分后平稳,就可以对差分后序列进行 ARMA 模型拟合了.

## 3 ARIMA 模型的新型 F 适用性检验

在 ARIMA 模型中,利用残差进行适用性检验,参数与观察值是非线性关系,只能得到残差估计的近似值,

且残差估计是参数的非线性函数,因此计算残差估计复杂,一般通过非线性最小二乘迭代求近似最优解,由于样本长度的有限性,样本方差取得最小值是不确定的,计算量大,精确性低. 残差方差图、最小信息准则、AIC 准则和利用自相关系数与偏自相关系数的拖尾或截尾等适用性检验所得到的网络流量模型都是备选模型,而需要做选择时,还应使用正规的统计检验.

AIC 准则为选择最优模型带来了很大的方便,但 AIC 准则也有不足之处. 对于一个观测值序列而言,序列越长,相关信息就越分散,要很充分地提取其中的有用信息,或者说要使得拟合精度比较高的话,通常需要多自变量复杂模型. 在 AIC 准则中拟合误差提供的信息要受到样本容量的放大,它等于  $n \ln(\hat{\sigma}_\varepsilon^2)$ , 但参数个数的惩罚因子却和样本容量没关系,它的权重始终是常数 2. 因此在样本容量趋于无穷大时,由 AIC 准则选择的模型不收敛于真实模型,它通常比真实模型所含的未知参数个数要多. 用 AIC 准则挑选的最佳模型的阶数往往是过相容的,也就是说选定的阶数往往比真实的阶数高. 下面给出一种新的检验方法,先采用自相关系数和偏自相关系数的拖尾对 ARIMA 模型检验,再对其进行 F 适用性检验,克服了由于观测样本的长度是有限的,偏相关的估计存在误差,拖尾时不能为 ARMA 定阶的缺陷,再通过正规的 F 统计检验,得到较为准确的 AIRMA 模型.

### 3.1 自相关系数与偏向相关系数的拖尾或截尾检验

将网络流量的观测值通过序列预处理,取对数运算及差分运算后,求出该观测值序列的样本自相关系数(Auto correlations coefficient, 简称 ACF)和样本偏自相关系数(partial Auto correlations coefficient, 简称 PAC)的值,根据样本自相关系数和偏自相关系数的性质,选择阶数适当的 ARMA( $p, q$ ) 模型进行拟合.

如果时间序列图和相关图都显示数据是平稳的,我们可先由样本 ACF $\{\hat{P}(k)\}$  和样本 PACF $\{\hat{\varphi}_{kk}\}$  试着识别阶( $p, q$ ), 根据詹金斯(Jenkins)和瓦茨(watts)于 1968 年对自相关数的证明  $E(\hat{\rho}_k) = \left[1 - \frac{k}{n}\right] \rho_k$  可知当样本容量  $n$  充分大时,样本自相关系数近似服从正态分布  $\hat{\rho}_k \sim N\left[0, \frac{1}{n}\right]$ . 昆诺伊尔(Quenouille)证明,偏自相关系数也同样近似服从这个正态分布  $\hat{\varphi}_{kk} \sim N\left[0, \frac{1}{n}\right]$ .

根据正态分布的性质,如果在所有的  $k > p$  中,大约由 95% 的  $k$  满足  $|\hat{\varphi}_{kk}| < 1.96/\sqrt{n}$ , 此时我们称  $\hat{\varphi}_{kkp}$  阶截尾,则我们拟合 AR( $p$ ) 模型(此时 ARMA( $p, q$ ) 模型当  $q = 0$  时的特例). 如果在所有的  $k > q$  中,大约由 95% 的  $k$  满足

$$|\rho_k| \leq 1.96 \left\{ 1 + 2 \sum_{j=1}^q \rho(j) \right\}^{\frac{1}{2}} \sqrt{n} \quad (3)$$

此时我们称  $\rho_k$  为  $q$  阶截尾, 则我们对数据拟合 MA ( $q$ ) 模型(此时为 ARMA( $p, q$ ) 模型当  $p=0$  时的特例)。

如果以上条件不满足, 即样本的相关系数不会呈现出理论截尾的充要情况, 本应截尾的样本自相关系数或偏自相关系数仍会呈现出小值振荡的情况, 而且由非零自相关系数衰减为小值波动的过程非常突出, 这时, 通常视为自相关系数截尾, 截尾阶数为  $q$ , 如果有超过 5% 的样本相关系数不满足上式(3)或者由显著非零的相关系数衰减为小值波动的过程比较缓慢或者非常连续, 这时通常视为相关系数拖尾, 此时应视为 ARMA( $p, q$ ) 模型, 还需使用其它方法确定  $p, q$ 。

在实际使用偏自相关函数曲线估计模型时还有一个困难, 这就是如何确定偏相关函数值是否真正为零。由于观测样本的长度是有限的, 偏相关的估计必然会有误差。利用自相关系数或偏自相关系数截尾时可以为 AR 或 MA 模型定阶, 但拖尾时不能为 ARMA 定阶。

### 3.2 ARIMA 模型的 F 适用性检验

我们把 F 检验应用于 ARIMA 模型适用性检验, 现在以 ARMA( $p, q$ ) 模型定阶为例, 加以说明。我们采用过拟合的办法, 先对观察数据用 ARMA( $p, q$ ) 模型进行拟合, 再假定  $\varphi_p, \theta_q$  高阶系数中某些取值为零, 用 F 检验准则来判定阶数降低之后的模型与 ARMA( $p, q$ ) 模型之间是否存在显著性差异, 如果差异显著, 则说明模型的阶数仍存在着升高的可能性; 若差异不显著, 则模型阶数可以降低。

利用 F 分布进行假设检验, 从而确定 ARMA( $p, q$ ) 模型的阶, 根据自相关系数及偏向相关系数的拖尾性, 利用 F 分布进行假设检验, 即当  $\varphi_p, \theta_q$  的值相当小( $\rightarrow 0$ )时, 我们假设  $H_0: \varphi_p = 0, \theta_q = 0$  记  $S_0$  为 ARMA( $p, q$ ) 模型的残差平方和,  $s_1$  为 ARMA( $p-1, q-1$ ) 模型的残差平方和, 则

$$F = \frac{s_1 - s_0}{2} \sqrt{\frac{s_0}{n-p-q}} \sim F(2, n-p-q)$$

其中  $n$  为样本长度,  $v = p+q$  是模型参数总个数,  $s = 2$  是被检验的参数个数。如果  $F > F_\alpha$  (一般取  $\alpha$  为 0.05 或 0.01, 通过  $F$  分布表, 查出  $F_\alpha$  相应的值), 则  $H_0$  不成立, 模型阶数仍有上升的可能, 否则  $H_0$  成立, 即 ARMA( $p-1, q-1$ ) 是适合的模型。

一般情况下, 我们可以从低阶到高阶逐个取( $p, q$ ) 为(1, 1), (1, 2), (2, 1), (2, 2), ... 等值进行尝试。

F 检验是正规的统计检验, 一般情况下采用自相关系数和偏自相关系数的拖尾对 ARMA 模型检验后, 再通过 F 适用性检验, 并采用变尺度法优化模型参数, 可以得到准确性高, 单一的 ARMA 模型。

## 4 基于变尺度 ARIMA 模型参数优化

对于网络流量  $\{y(t)\} (t=1, 2, \dots, n)$ , 经预处理后得到的观测时序  $\{x(t)\} (t=1, 2, \dots, n)$ , 需对其拟合出数学模型:

$$x(t) = f(Z(t), \beta) + \varepsilon(t) \quad (4)$$

式中  $Z(t) = [x(t-1), \dots, x(t-k)]^T$ , 它是由不同时刻的观测值组成的  $k$  维向量,  $\beta = [\beta_1, \beta_2, \dots, \beta_m]^T$ , 它是由待估计的模型参数  $\beta_i, i=1, \dots, m$  组成的  $m$  维向量, 一般  $k, m < n$ ;  $\varepsilon(t)$  是模型的残差;  $f$  表示  $Z(t)$  与  $\beta$  之间的函数关系。因此, 对于 ARMA 模型  $Z(t)$  与  $\beta$  之间具有非线性关系, 从而 ARMA 模型的目标函数  $s(\beta)$  定义为模型的残差平方和。

$$s(\beta) = \sum_{t=p+1}^n \varepsilon^2(t) = \sum_{t=p+1}^n [x(t) - f(Z(t), \beta)]^2 \quad (5)$$

从优化理论的角度来看, 参数  $\beta$  的估值问题就是对  $s(\beta)$  的寻优(求极小值)问题。文中对 ARMA 模型参数的估值问题, 利用优化理论中的变尺度算法, 推出参数估值的迭代算法。

关于参数初值  $\beta^0$  和残差  $\varepsilon(t)$  初值的确定, 这里不作详细论述, 下面介绍基于变尺度 ARIMA 模型的参数优化迭代算法。

迭代步骤:

(1) 对于 ARMA( $p, q$ ) 的模型式

$$x(t) = \varphi_1 x(t-1) + \varphi_2 x(t-2) + \dots + \varphi_p x(t-p) - \theta_1 \varepsilon(t-1) - \theta_2 \varepsilon(t-2) - \dots - \theta_q \varepsilon(t-q) + \varepsilon(t)$$

设  $Z$  给定了参数初值

$$\beta^0 = (\beta_1^0, \beta_2^0, \dots, \beta_m^0)^T = [\varphi_1^0, \dots, \varphi_p^0, \theta_1^0, \dots, \theta_q^0]^T$$

$m = p+q$  梯度模的允许误差  $\varepsilon > 0$ , 初始对称正是矩阵  $D_0$  (文中取  $D_0$  为单位阵  $I_0$ )。

由式(5), 残差平方和  $s(\beta)$  在  $\beta^0$  处的梯度为

$$g_i^0 = \left. \frac{\partial s(\beta)}{\partial \beta_i} \right|_{\beta=\beta^0} = -2 \sum_{t=p+1}^n \left\{ [x(t) - f(Z(t), \beta)], \frac{\partial f(Z(t), \beta)}{\partial \beta_i} \right\} \Big|_{\beta=\beta^0} \quad i=1, 2, \dots, m \quad (6)$$

写成向量形式为:

$$g^0 = \left. \frac{\partial s(\beta)}{\partial \beta} \right|_{\beta=\beta^0} = \left[ \left. \frac{\partial s(\beta)}{\partial \beta_1} \right|_{\beta=\beta^0}, \dots, \left. \frac{\partial s(\beta)}{\partial \beta_m} \right|_{\beta=\beta^0} \right]^T \quad (7)$$

为了便于计算, 在  $\beta^0$  处时 ARMA 模型中的  $f(Z(t), \beta)$  进行泰勒展开:

$$f(Z(t), \beta) = f(Z(t), \beta^0) + (\beta_1 - \beta_1^0) \left. \frac{\partial f(Z(t), \beta)}{\partial \beta_1} \right|_{\beta=\beta^0} + (\beta_2 - \beta_2^0) \left. \frac{\partial f(Z(t), \beta)}{\partial \beta_2} \right|_{\beta=\beta^0} + \dots + (\beta_m - \beta_m^0) \left. \frac{\partial f(Z(t), \beta)}{\partial \beta_m} \right|_{\beta=\beta^0}$$

$$+ o\left((\beta_1 - \beta_1^0)^2 + (\beta_2 - \beta_2^0)^2 + \dots + (\beta_m - \beta_m^0)^2\right) \quad (8)$$

记

$$\delta(t) = \varepsilon(t) + o\left((\beta_1 - \beta_1^0)^2 + (\beta_2 - \beta_2^0)^2 + \dots + (\beta_m - \beta_m^0)^2\right)$$

由式(4)和式(8), 有

$$\begin{aligned} \varepsilon^0(t) &= \mathbf{x}(t) - f(\mathbf{Z}(t), \beta^0) \\ &= (\beta_1 - \beta_1^0) \frac{\partial f(\mathbf{Z}(t), \beta)}{\partial \beta_1} \bigg|_{\beta=\beta^0} \\ &\quad + (\beta_2 - \beta_2^0) \frac{\partial f(\mathbf{Z}(t), \beta)}{\partial \beta_2} \bigg|_{\beta=\beta^0} + \dots \\ &\quad + (\beta_m - \beta_m^0) \frac{\partial f(\mathbf{Z}(t), \beta)}{\partial \beta_m} \bigg|_{\beta=\beta^0} + \delta(t) \quad (9) \end{aligned}$$

证  $u_i^0 = \beta_i - \beta_i^0, i = 1, 2, \dots, m$

$$w_i^0(t) = \frac{\partial f(\mathbf{Z}(t), \beta)}{\partial \beta_i} \bigg|_{\beta=\beta^0}, i = 1, 2, \dots, m$$

写成向量形式为

$$\mathbf{u}^0 = [u_1^0, u_2^0, \dots, u_m^0]^T \quad (10)$$

$$\mathbf{w}^0(t) = [w_1^0(t), w_2^0(t), \dots, w_m^0(t)]^T \quad (11)$$

由式(9)~(11)有

$$\varepsilon^0(t) = [\mathbf{u}^0]^T \mathbf{g} \mathbf{w}^0(t) + \delta(t) \quad (12)$$

当  $t = p+1, p+2, \dots, n$  时, 可有:

$$\mathbf{W}^0 = \begin{bmatrix} w_1^0(p+1) & w_1^0(p+2) & \dots & w_1^0(n) \\ w_2^0(p+1) & w_2^0(p+2) & \dots & w_2^0(n) \\ \vdots & \vdots & \ddots & \vdots \\ w_m^0(p+1) & w_m^0(p+2) & \dots & w_m^0(n) \end{bmatrix} \quad (13)$$

$$\delta = [\delta(p+1), \delta(p+2), \dots, \delta(n)]^T \quad (14)$$

$$\varepsilon^0 = [\varepsilon^0(p+1), \varepsilon^0(p+2), \dots, \varepsilon^0(n)]^T \quad (15)$$

由式(6), 式(9)及式(12)有

$$g_i^0 = g_i(\beta^0) = -2 \sum \varepsilon^0(t) w_i^0(t), i = 1, 2, \dots, m \quad (16)$$

由式(7), 式(13)~(15)有

$$\delta^0 = \delta(\beta^0) = -2 \mathbf{W}^0 \varepsilon^0 \quad (17)$$

(2) 设  $y^0 = \beta^0$ , 令  $i = j = 0$ , 转步骤(3).

(3) 检验是否满足收敛性判别准则  $\|g^0\| < \varepsilon$  若满足, 则迭代停止, 得到  $y^0 = \beta^0 \approx \beta_{\min}$  否则转(4).

(4) 令  $d_j = -D_j g^j$ .

(5) 用一维搜索方法[可采用斐波那契(Fibonacci)法或黄金分割(0.618)法]求单变量极值问题最优解  $\lambda_j$

$$\min_{\lambda} s(y^j + \lambda d_j) = s(y^j + \lambda d_j)$$

(6) 令  $y^j = y^j + \lambda_j d_j$ . 如果  $j < m$  转步(7). 如果  $j = m$ . 令  $y^j = x^{i+1} = y^{m+1}$ , 用  $i+1$  代替  $i$ , 转步(3).

(7) 构造  $D_{j+1}$  如下:

$$D_{j+1} = D_j + \frac{\Delta y^j (\Delta y^j)^T}{(\Delta y^j)^T \Delta g^j} - \frac{D_j g^j (\Delta g^j)^T D_j^T}{(\Delta g^j)^T D_j \Delta g^j}$$

这里:  $\Delta y^j = y_{j+1} - y^j$ ,

$$\Delta g^j = g^{j+1} - g^j = g(y^{j+1}) - g(y^j)$$

(8) 置  $j = j+1$  转步(4).

变尺度法是优化理论中求解函数无约束极值问题的最有效迭代方法之一, 它具有收敛速度快、只需一阶导数的信息、不求逆阵、每次迭代仅只需  $o(n^2)$  次乘法运算(牛顿法为  $o(n^3)$ )、方法所需的存储单元一样为  $n^2/2 + o(n)$  和具有超线性收敛性等诸多优点, 采用变尺度法对模型参数进行优化, 可以得到较为精确的 AIRMA 模型.

## 5 仿真研究

我们从2006年3月3日8时至3月5日8时, 以5分钟间隔获取了共500组 CERNET 某省文献数据中心主干网络出口流量数据, 如图1所示, 该数据序列不是平稳序列, 文中将其取对数的观测数据  $y(t)$  经过一阶差分后, 根据自相关系数图(如图2所示)和偏自相关系数图(如图3所示), 在经过  $F$  适用性检验后, 我们拟合了一个 ARMA(2, 2) 模型(如图4所示), 其中的参数  $\varphi_1 = 0.98$ ,  $\varphi_2 = -0.04$ ,  $\varepsilon_1 = -0.6$ ,  $\varepsilon_2 = -0.01$  是用加权迭代参数估计算法得到的, 于是拟合的模型如下,

$$x(t) = 0.98x(t-1) - 0.04x(t-2) + \varepsilon(t) - 0.06\varepsilon(t-1) - 0.01\varepsilon(t-2) \mid \varepsilon(t) \sim_{i.i.d} N(0, 0.05)$$

从参数之中可判断该模型是平稳的.




图1 原始流量数据




图2 自相关系数




图3 偏自相关系数




图4 拟合模型

## 6 结论

本文给出采用自相关系数和偏自相关系数的拖尾先对 ARIMA 模型检验, 再对其进行  $F$  适用性检验, 克服了由于观测样本的长度是有限的, 偏相关的估计存在误差, 拖尾时不能为 ARMA 定阶的缺陷, 再通过正规的  $F$  统计检验, 并采用具有超线性收敛性等诸多优点的变尺度法对模型参数进行了优化, 得到了较为精确的、单一 AIRMA 模型, 而传统的残差方差图, AIC 准则和利用相关系数拖尾或截尾等方法都存在计算量大、准确性低和

模型不唯一等缺陷,该方法可应用于网络流量模型的检验与模型参数优化,为网络流量的预测、异常检测和服务器负载预测的应用奠定了坚实的基础,具有理论意义和实用价值。

#### 参考文献:

- [1] Fowler H J, Leland W E. Local area network traffic characteristics, with implications for broadband network congestion management[J]. IEEE JSAC, 1991, 9(7): 1139– 1149.
- [2] Paxson V, Floyd S. Widearea traffic: the failure of poisson modeling[J]. IEEE/ACM Transactions on Networking, 1995, 3(3): 226– 244.
- [3] Erramilli A, Narayan O, Willinger W. Experimental queueing analysis with long-range dependent packet traffic[J]. IEEE/ACM Transactions on Networking, 1996, 4(2): 209– 223.
- [4] 陈果. 基于遗传算法的 ARMA 模型定阶新技术[J]. 机械工程学报, 2005, 41(1): 41– 45.  
Chen Guo. New technique for determining the order of ARMA model based on genetic algorithm. [J]. Chinese Journal of Mechanical Engineering, 2005, 41(1): 41– 45. (in Chinese)
- [5] 贺国光, 马寿峰, 李宇. 基于小波分解与重构的时间序列预测法. [J]. 自动化学报, 2002, 28(6): 1012– 1014.  
He Guo guang Ma Shou feng, Li Yu. A Study on forecasting for time series based on wavelet analysis[J]. Acta Automatica Sinica, 2002, 28(6): 1012– 1014. (in Chinese)

- [6] 孙靖, 程大章. 基于季节性时间序列模型的空调负荷预测[J]. 电工技术学报, 2004, 19(3): 88– 93.

Sun Jing, Cheng Dazhang. Air conditioning load prediction based on seasonal time series methods. [J]. Transactions of China Electrotechnical Society, 2004, 19(3): 88– 93. (in Chinese)

#### 作者简介:



单 伟 女, 1969 年 12 月生于黑龙江省哈尔滨市, 燕山大学测试计量技术及仪器专业博士研究生, 主要研究方向为时间序列分析和网络控制等, 发表论文 10 余篇。

E-mail: sw@ysu.edu.cn



何 群 男, 1969 年 10 月生于陕西省西安市, 副教授、博士后, 主要研究方向为预测控制和虚拟仪器等, 发表论文 20 余篇, 获机械工业科学技术奖等省部级奖 2 项。

E-mail: hq@ysu.edu.cn