

## Parameter estimation of a linear process

東工大 理 柴田 里程

Time series analysis において、よく想定される母集団の process は AR, MA, ARMA process 等であるが、それほど構造のはっきりしていない場合には、もっと一般に one sided linear stationary process であるとして、話を進める必要がある [3], [4], [7].

ここでは、そのような process の無限個のパラメータの推定、およびその推定されたパラメータを使って予測を行なったときの予測誤差を問題にする。

§1 では best predictor の係数の最尤推定量は、実は、対応する order の AR を fit したときの Yule-Walker equation の解であることを示し、§2 ではその optimal な order を求め、§3 で efficient な selection method を与える。

### §1. Prediction and parameter estimation

$\{x_t\}$  は平均 0 の one sided linear stationary Gaussian process;

$$x_t + a_1 x_{t-1} + \dots = e_t \quad (t = \dots, -1, 0, 1, \dots) \quad (1-1)$$

であるとする。ただし,  $e_t$  は  $N(0, \sigma^2)$  に従う i.i.d. と associated polynomial  $A(z) = 1 + a_1 z + \dots$  は  $|z| \leq 1$  で finite, nonzero であるとする。correlation と  $r_l = E(x_t x_{t+l})$ ,  $k \times k$  covariance matrix と  $R(k)$  で表わす。

よって  $R$ , vector space  $\{\alpha' = (\alpha_1, \alpha_2, \dots)\}$  に

$$\|\alpha\|_R^2 = \sum_{i,j=1}^{\infty} \alpha_i \alpha_j r_{|i-j|}$$

なる norm を導入し, この norm によるパラメータ  $\alpha' = (\alpha_1, \alpha_2, \dots)$  の  $(h+k-1)$ -dim. subspace

$$\{\alpha' = (0, \dots, 0, \alpha_h, \alpha_{h+1}, \dots, \alpha_{h+k-1}, 0, \dots, 0)\}$$

への projection と

$$\underline{a}'(h, k) = (0, \dots, 0, a_h(h, k), \dots, a_{h+k-1}(h, k), 0, \dots)$$

とするのは, よく知られているように  $R$ , この  $k$  step 前からの観測値  $x_{t-k+1}, \dots, x_t$  にもとづく  $h$  step 先の  $x_{t+h}$  の best predictor  $\hat{x}_{t+h}$  の係数を表わす vector になっている。すなわち

$$\hat{x}_{t+h} = E(x_{t+h} | x_{t-k+1}, \dots, x_t) = \sum_{i=h}^{h+k-1} \underline{a}_i(h, k) x_{t+h-i}$$

さて,  $n$ -samples  $x_1, \dots, x_n$  が与えられたときの  $Q(h, k)$  の M.L.E. を求めよう。

### Theorem 1.1

$Q(h, k)$  の  $\rightarrow$  の M.L.E. は次の equation

$$\sum_{j=h}^{h+k-1} \hat{r}_{|i-j|} \hat{a}_j(h, k) = -\hat{r}_i \quad (i=h, \dots, h+k-1) \quad (1-2)$$

の解

$$\hat{a}(h, k)' = (0, \dots, 0, \hat{a}_h(h, k), \dots, \hat{a}_{h+k-1}(h, k), 0, \dots)$$

で与えられる。ただし,  $h+k \leq n$ ,  $\hat{r}_l = \frac{1}{n-l} \sum_{t=1}^{n-l} x_t x_{t+l}$ .

Proof.  $f(x_1, \dots, x_n, \theta)$  が  $x_1, \dots, x_n$  の同時密度を表わせば,

$r_0, r_1, \dots, r_{n-1}$  は  $\theta$  と  $\sigma^2$  の関数であるから

$$\begin{aligned} \max_{\theta, \sigma^2} f(x_1, \dots, x_n, \theta, \sigma^2) &\leq \max_{r_0, \dots, r_{n-1}} f(x_1, \dots, x_n, r_0, \dots, r_{n-1}) \\ &= f(x_1, \dots, x_n, \hat{r}_0, \dots, \hat{r}_{n-1}) \end{aligned}$$

よって,  $\{r_i\}_{i=0}^{\infty}$  と  $\theta$  の関係

$$\sum_{j=1}^{\infty} r_{|i-j|} a_j = -r_i \quad (i=1, 2, \dots) \quad (1-3)$$

より,  $r_l^* = \hat{r}_l$  ( $l=0, 1, \dots, n-1$ ) であるような  $\{r_i^*\}_{i=0}^{\infty}$

に対し (1-3) を満たし,  $A(z)$  が  $|z| \leq 1$  で finite,

nonzero であるような  $\theta^*$  が  $\theta$  の  $\rightarrow$  の M.L.E. となる。し

たがって,  $Q(h, k)$  の M.L.E. は  $\theta^*$  の  $\|\cdot\|_{R^*}$  による projection で与えられるから, 結局 (1-2) の解となる。』

ところで, theorem 1.1 の  $\hat{a}(h, k)$  は, 実は,  $(h+k-1)$  th order AR model

$$x_{t+h} + \alpha_1 x_{t+h-1} + \dots + \alpha_{h+k-1} x_{t-k+1} = \varepsilon_t$$

(ただし,  $\alpha_1 = \alpha_2 = \dots = \alpha_{h-1} = 0$ )

を fit させるとき

$$\alpha' = (0, \dots, 0, \alpha_h, \dots, \alpha_{h+k-1}, 0, \dots)$$

の approximate M.L.E. (Yule-Walker equation (1-2) の解) に他ならない。したがって

「AR model を fit させるとき Yule-Walker equation の解」

$\Leftrightarrow$  「対応する predictor の係数の M.L.E.」

であることがわかる。

さて, 話を簡単にするために,  $\{x_t\}$  と同じ構造をもちこれと独立なもう一つの process  $\{y_t\}$  を考え, 推定したパラメータ  $\hat{a}(h, k)$  を使って  $t \rightarrow k$  predictor

$$\hat{y}_{t+h} = - \sum_{i=h}^{h+k-1} \hat{a}_i(h, k) y_{t+h-i}$$

の mean squared error を求めると

$$\begin{aligned} E^y (\hat{y}_{t+h} - y_{t+h})^2 &= \|\hat{a}(h, k) - a\|_R^2 + \sigma^2 \\ &= \|\hat{a}(h-k) - \underline{a}(h, k)\|_R^2 + \|\underline{a}(h, k) - a(h, \infty)\|_R^2 \\ &\quad + \|a(h, \infty) - a\|_R^2 + \sigma^2 \end{aligned} \quad (1-4)$$

となる。ただし,  $\underline{a}(h, \infty)$  は  $\{\alpha' = (0, \dots, 0, \alpha_h, \alpha_{h+1}, \dots)\}$  への  $\underline{a}$  の projection で  $h=1$  なら  $\underline{a}(h, \infty) = \underline{a}$ . (1-4) は, また  $\hat{x}_{n+h} - x_{n+h}$  の漸近分散とも漸近的には等しく, 第1項は推定量のバラツキ, 第2項は bias, 第3, 4項は予測のバラツキを表わしている。さらに,  $\|\hat{a}(h, k) - \underline{a}\|_R^2$  なる loss function は,  $h, k$  を fix したときの  $\hat{a}(h, k)$  の漸近分散行列 (= Fisher information matrix) で normalize した quadratic loss function でもある。

(1-4) の第1項は  $k$  を fix したとき  $\frac{1}{n}$  の order で 0 に確率収束するが, そのとき第2項は  $\{x_t\}$  が  $h+k-1$  より低い order の AR でない限り残ってしまう。そこで,  $k$  を  $n$  に depend して決めていくことにより第1項, 第2項を balance させながら, 第1項+第2項を最小に持っていくことが必要になる。

## §2. Efficiency of a selection method

$h=1$  の場合だけを考えれば, あとは同様であるので, 以後, この場合だけを考え簡単に  $\underline{a}(k) = \underline{a}(1, k)$  と表わす。また,  $k$  の上限  $\bar{K}_n (< n)$  を与え,  $1 \leq k \leq \bar{K}_n$  の範囲で考える。

Notations.

$$X_j(k)' = (x_j, x_{j-1}, \dots, x_{j-k+1})$$

$$\begin{aligned}\hat{R}(k) &= (\hat{r}_{\ell, m} \quad 1 \leq \ell, m \leq k) \\ &= \frac{1}{n} \sum_{j=\bar{K}_n}^{n-1} X_{j+1}(k) X'_{j+1}(k)\end{aligned}$$

$$\hat{r}(k)' = (\hat{r}_{0,1}, \hat{r}_{0,2}, \dots, \hat{r}_{0,k})$$

$$\hat{a}(k) = (\hat{a}_1(k), \hat{a}_2(k), \dots, \hat{a}_k(k), 0, \dots)$$

$$: \hat{R}(k) \hat{a}(k) = -\hat{r}(k) \text{ の解}$$

( $\hat{a}(k)$  は  $k$ -dim. vector とみる)

$$e_{j+1, k} = x_{j+1} + a_1(k)x_j + \dots + a_k(k)x_{j+1-k}$$

$$s_k^2 = \frac{1}{n} \sum_{j=\bar{K}_n}^{n-1} e_{j+1, k}^2$$

$$\sigma_k^2 = E(e_{j+1, k}^2)$$

さらに,  $\|\cdot\|$  は通常 Euclid norm を表わす.

Remark.

$\hat{a}(k)$  は §1 の  $\hat{a}(1, k)$  とは厳密には違っているが, 漸近的には同等である。ここでは,  $\hat{a}(k)$  を採用し, loss  $\|\hat{a}(k) - a\|_R^2$  を問題にする。

Assumptions

$$(A-1) \quad \sum_{j=1}^{\infty} |a_j| < \infty$$

$$(A-2) \quad A(e^{i\lambda}) \neq 0 \quad \cdot (-\pi \leq \lambda \leq \pi)$$

$$(A-3) \quad \sum_{j=1}^{\infty} |r_j| < \infty$$

$$(A-4) \quad \bar{K}_n = o(\sqrt{n})$$

(A-5)  $\{x_t\}$  は finite order の AR ではない。

Lemma 2.1

(A-1) ~ (A-3) の仮定のもとで, ある absolute constants  $c_1, c_2 > 0$  が存在して  $\bar{K}_n \geq \forall k \geq 1$  に対して

$$\begin{aligned} E \left( \frac{n}{k} \left\| \sum_{j=\bar{K}_n}^{n-1} X_j(k) e_{j+1} / n \right\|_{R(k)^{-1}}^2 - \sigma^2 \right)^2 \\ \leq \left( 1 - \frac{\bar{K}_n}{n} \right) \frac{c_1}{n} + \left( 1 - \frac{\bar{K}_n}{n} \right)^2 \frac{c_2}{k} \end{aligned}$$

Proof. Gaussian property を使って,  $\{x_t\}$  の 8 次モーメントを評価すれば結果を得る。  $\square$

Lemma 2.2

(A-1) ~ (A-3) の仮定のもとで, ある absolute constant  $c_3 > 0$  が存在して  $\bar{K}_n \geq \forall k \geq 1$  に対して

$$\begin{aligned} E \left( \frac{n}{k} \left\| \sum_{j=\bar{K}_n}^{n-1} X_j(k) (e_{j+1,k} - e_{j+1}) / n \right\|^2 \right) \\ \leq c_3 \left( 1 - \frac{\bar{K}_n}{n} \right) \|a - \underline{a}(k)\|^2 \end{aligned}$$

Proof. see [7].  $\square$

Lemma 2.3

(A-1), (A-2), (A-4) の仮定のもとで

$$p - \lim_{n \rightarrow \infty} \left( \max_{k \leq \bar{K}_n} \|\hat{R}(k) - R(k)\| \right) = 0$$

$$p\text{-}\lim_{n \rightarrow \infty} \left( \max_{k \leq \bar{K}_n} \|\hat{R}(k)^{-1} - R(k)^{-1}\| \right) = 0$$

ただし, matrix  $A$  の norm は  $\|A\| = \sup_{\|x\| \leq 1} \|Ax\|$  で定

義される。

$$\text{Proof. } \max_{k \leq \bar{K}_n} \|\hat{R}(k) - R(k)\| \leq \|\hat{R}(\bar{K}_n) - R(\bar{K}_n)\|$$

であることと, [3] より従う。  $\square$

$$\hat{a}(k) - \underline{a}(k) = -\hat{R}(k)^{-1} \left( \sum_{j=\bar{K}_n}^{n-1} X_j(k) \underline{e}_{j+1,k} / n \right)$$

であるので, 上の三つの lemma と  $\|R(k)^{-1}\|$  が bounded であることより, 次の proposition を得る。

### Proposition 2.1

(A-1) ~ (A-4) の仮定のもとで,  $1 \leq k_n \leq \bar{K}_n$  と  $\liminf_n k_n = \infty$  なる任意の positive integer の sequence  $\{k_n\}$  に対して

$$p\text{-}\lim_{n \rightarrow \infty} \left| \frac{n}{k_n} \|\hat{a}(k_n) - \underline{a}(k_n)\|_R^2 - \sigma^2 \right| = 0.$$

したがって,  $\|\hat{a}(k_n) - \underline{a}\|_R^2$  は漸近的に

$$L_n(k_n) = \frac{k_n}{n} \sigma^2 + \|\underline{a} - \underline{a}(k_n)\|_R^2$$

に等しくなる。



## Definition 2.1

$k_n^*$  は  $L_n(k_n^*) = \min_{1 \leq k \leq \bar{K}_n} L_n(k)$  なる positive integer.

(A-5) の仮定のもとで,  $\{k_n^*\}$  は  $n \rightarrow \infty$  として monotone increasing であり  $\lim_n k_n^* = \infty$  なる sequence となる。

## Theorem 2.1

(A-1) ~ (A-5) の仮定のもとで, 任意の  $1 \leq k_n \leq \bar{K}_n$   
 $n \rightarrow \infty$

$$p - \lim_{n \rightarrow \infty} \frac{\|\hat{a}(k_n) - a\|_R^2}{\|\hat{a}(k_n^*) - a\|_R^2} \geq 1 \quad (2-1)$$

Proof.

$$\frac{\|\hat{a}(k_n) - a\|_R^2}{\|\hat{a}(k_n^*) - a\|_R^2} = \frac{L_n(k_n^*)}{\|\hat{a}(k_n^*) - a\|_R^2} \cdot \frac{\|\hat{a}(k_n) - a\|_R^2}{L_n(k_n)} \cdot \frac{L_n(k_n)}{L_n(k_n^*)}$$

より, proposition 2.1 より

$$p - \lim_{n \rightarrow \infty} \frac{L_n(k_n^*)}{\|\hat{a}(k_n^*) - a\|_R^2} = 1$$

また,

$$\begin{aligned} \frac{k}{(n L_n(k))^2} &\leq \frac{1}{n L_n(k) \sigma^2} \\ &\leq \frac{1}{n L_n(k_n^*) \sigma^2} \leq \frac{1}{k_n^* \sigma^4} \end{aligned}$$

であるから, lemma 2.1 ~ 2.3 より proposition 2.1 と同様にして

$$p\text{-}\lim_{n \rightarrow \infty} \frac{\|\hat{a}(k_n) - a\|_R^2}{L_n(k_n)} = 1$$

□

この theorem より  $k_n^*$  が漸近的に最も optimal な order であることがわかる。しかし, これはパラメータに依存し, 一般には unknown。そこで何らかの integer valued statistic  $\tilde{k}_n$  が  $k_n^*$  を推定することを考えよう。

まず proposition 2.1 を拡張し, 次の proposition を得る。

Proposition 2.2

(A-1) ~ (A-5) の仮定のもとに,  $1 \leq l_n \leq m_n \leq \bar{K}_n$ ,  $\lim_{n \rightarrow \infty} \frac{m_n}{l_n} = 1$  なる任意の integer の sequences  $\{l_n\}$ ,

$\{m_n\}$  に対して

$$p\text{-}\lim_{n \rightarrow \infty} \left( \max_{l_n \leq k \leq m_n} \left| \frac{\|\hat{a}(k) - a\|_R^2}{L_n(k)} - 1 \right| \right) = 0.$$

Proof.

lemma 2.1 より

$$\begin{aligned} & \sum_{k=l_n}^{m_n} E \left( \frac{\frac{n}{k} \left\| \sum_{j=\bar{K}_n}^{n-1} X_j(k) e_{j+1} / n \right\|_{R(k)^{-1}}^2 - \sigma^2}{\frac{n}{k} L_n(k)} \right)^2 \\ & \leq c_1' \frac{\bar{K}_n^2}{n} + c_2' \sum_{k=l_n}^{m_n} \frac{k}{(n L_n(k))^2} \end{aligned}$$

また, lemma 2.2 より

$$\sum_{k=l_n}^{m_n} E \left( \frac{\sqrt{\frac{n}{k}} \left\| \sum_{j=\bar{K}_n}^{n-1} X_j(k) e_{j+1, k} / n \right\|_{R(k)^{-1}} - \sqrt{\frac{n}{k}} \left\| \sum_{j=\bar{K}_n}^{n-1} X_j(k) e_{j+1} / n \right\|_{R(k)^{-1}}}{\sqrt{\frac{n}{k} L_n(k)}} \right)^2$$

$$\leq c'_3 \frac{\bar{K}_n^2}{n}$$

また,  $l'_n = \min(l_n, \log k_n^*)$ ,  $m'_n = \min(m_n, \log k_n^*)$  とすれば

$$\sum_{k=l'_n}^{m'_n} \frac{k}{(n L_n(k))^2} \leq \text{const.} \frac{(\log k_n^*)^2}{k_n^{*2}}$$

$l''_n = \max(l_n, \log k_n^*)$ ,  $m''_n = \max(m_n, \log k_n^*)$  とすれば

$$\sum_{k=l''_n}^{m''_n} \frac{k}{(n L_n(k))^2} \leq \text{const.} \sum_{k=l''_n}^{m''_n} \frac{1}{k}$$

よって,  $\{l_n\}$ ,  $\{m_n\}$  の条件より

$$p\text{-}\lim_{n \rightarrow \infty} \left( \max_{l_n \leq k \leq m_n} \left| \frac{\|\hat{a}(k) - a(k)\|_R^2 - \frac{k}{n} \sigma^2}{L_n(k)} \right| \right) = 0. \quad \square$$

### Theorem 2.2

(A-1) ~ (A-5) の仮定のもとに, ある sequence  $\{k_n\}$  ( $1 \leq k_n \leq \bar{K}_n$ ) と positive constant  $d$  が存在して

$$p\text{-}\lim_{n \rightarrow \infty} \frac{\tilde{k}_n}{k_n} = d$$

であるよりの order selection  $1 \leq \tilde{k}_n \leq \bar{K}_n$  について,  
次の不等式が成り立つ。

$$p\text{-}\lim_{n \rightarrow \infty} \frac{\|\hat{a}(\tilde{k}_n) - a\|_R^2}{\|\hat{a}(k_n^*) - a\|_R^2} \geq 1 \quad (2-2)$$

Proof.

proposition 2.2 より  $p\text{-}\lim_{n \rightarrow \infty} \frac{\tilde{k}_n}{k_n} = a$  の条件を使えば

$$p\text{-}\lim_{n \rightarrow \infty} \frac{\|\hat{a}(\tilde{k}_n) - a\|_R^2}{\|\hat{a}(k_n^*) - a\|_R^2} = p\text{-}\lim_{n \rightarrow \infty} \frac{L_n(\tilde{k}_n)}{L_n(k_n^*)}$$

で,  $k_n^*$  の定義より (2-2) が従う。  $\square$

そこで, (2-2) の左辺の極限が存在し, 等号が成り立つとき,  $\tilde{k}$  は efficient であるといふことにする。

### §3. An efficient selection method

$S_n(k) = (n+2k) \hat{\sigma}_k^2$  なる statistic を考える。ただし

$$n \hat{\sigma}_k^2 = \sum_{j=K_n}^{n-1} (x_{j+1} + \hat{a}_1(k)x_j + \dots + \hat{a}_k(k)x_{j+1-k})^2.$$

すると  $S_n(\hat{k}_n) = \min_{1 \leq k \leq \bar{K}_n} S_n(k)$  なる  $\hat{k}_n$  が一つの efficient selection method となる。これは赤池の FPE 法, AIC 法 [1], [6] や Mallows の  $C_p$  法 [5] と同じような方法であるが,  $\hat{\sigma}_k^2$  や  $\hat{a}(k)$  の定義がいくぶんちがいがあ

$S_n(k)$  の behaviour は  $\hat{\sigma}_k$  critical  $\hat{\sigma}_k$ , 今の段階では上の  $\hat{k}_n$   $\hat{\sigma}_k$  といふ efficient  $\hat{\sigma}_k$  であるといふ事はない。

まず,  $S_n(k)$  を次のように書きかえる。

$$\begin{aligned} S_n(k) &= n(\hat{\sigma}_k^2 - \underline{S}_k^2) + n(\underline{S}_k^2 - \sigma_k^2) \\ &\quad + n(\sigma_k^2 - \sigma^2) + 2k\sigma^2 + 2k(\hat{\sigma}_k^2 - \sigma^2) \\ &= nL_n(k) - (n\|\hat{a}(k) - \underline{a}(k)\|_{\hat{R}(k)}^2 - k\sigma^2) \\ &\quad + 2k(\hat{\sigma}_k^2 - \sigma^2) + n(\underline{S}_k^2 - \sigma_k^2). \end{aligned}$$

### Lemma 3.1

(A-1) ~ (A-5) の仮定のもとで, 任意の sequence  $\{k_n\}$  ( $1 \leq k_n \leq \bar{k}_n$ ) に対し

$$p\text{-}\lim_{n \rightarrow \infty} \left| \frac{n\|\hat{a}(k_n) - \underline{a}(k_n)\|_{\hat{R}(k_n)}^2 - k_n\sigma^2}{nL_n(k_n)} \right| = 0$$

Proof.

$$\begin{aligned} &\frac{n\|\hat{a}(k_n) - \underline{a}(k_n)\|_{\hat{R}(k_n)}^2 - k_n\sigma^2}{nL_n(k_n)} \\ &= \frac{\|\hat{a}(k_n) - \underline{a}(k_n)\|_{\hat{R}(k_n)}^2 + \|\underline{a}(k_n) - \underline{a}\|_R^2}{L_n(k_n)} - 1 \end{aligned}$$

であるから, proposition 2.2 と lemma 2.3 より結果を得る。

## Lemma 3.2

lemma 3.1 と同じ仮定のもとで

$$p\text{-}\lim_{n \rightarrow \infty} \frac{k_n |\hat{\sigma}_{k_n}^2 - \sigma^2|}{n L_n(k_n)} = 0$$

Proof.

$$\begin{aligned} |\hat{\sigma}_k^2 - \sigma^2| &\leq |\hat{\sigma}_k^2 - \underline{S}_k^2| + |\underline{S}_k^2 - \sigma_k^2| + |\sigma_k^2 - \sigma^2| \\ &= \|\hat{a}(k) - \underline{a}(k)\|_{\hat{R}(k)}^2 + |\underline{S}_k^2 - \sigma_k^2| \\ &\quad + \|\underline{a}(k) - a\|_R^2 \end{aligned}$$

であることと, ある  $k$   $k$  depend しない  $c$  ( $> 0$ ) が存在して

$$E(\underline{S}_k^2 - \sigma_k^2)^2 \leq \frac{c}{n}$$

と評価されるから, lemma 3.1 より結果が従う。  $\square$

以上の lemma より

$$S_n(k_n) = n L_n(k_n) (1 + \delta_n) + n (\underline{S}_{k_n}^2 - \sigma_{k_n}^2)$$

と表わされる。ただし,  $\delta_n$  は  $p\text{-}\lim_{n \rightarrow \infty} \delta_n = 0$  なる r. v.

## Lemma 3.3

lemma 3.1 と同じ仮定のもとで

$$p\text{-}\lim_{n \rightarrow \infty} \left| \frac{n(\underline{S}_{k_n^*}^2 - \sigma_{k_n^*}^2) - n(\underline{S}_{k_n}^2 - \sigma_{k_n}^2)}{n L_n(k_n)} \right| = 0$$

Proof.

$k_n^* < k$  のとき

$$\begin{aligned} n(\underline{S}_{k_n^*}^2 - \sigma_{k_n^*}^2) - n(\underline{S}_k^2 - \sigma_k^2) \\ = 2n(\underline{a}(k_n^*) - \underline{a}(k))'(\hat{r}(k_n) - r(k_n)) \\ + n(\|\underline{a}(k_n^*)\|_{\hat{R}(k)}^2 - \|\underline{a}(k_n^*)\|_R^2 + \|\underline{a}(k)\|_R^2 - \|\underline{a}(k)\|_{\hat{R}(k)}^2) \end{aligned}$$

$$\begin{aligned} \leq E\left((n(\underline{a}(k_n^*) - \underline{a}(k)))'(\hat{r}(k) - r(k))\right)^2 \\ \leq \text{const. } n \|\underline{a}(k_n^*) - \underline{a}(k)\|_R^2, \end{aligned}$$

また,

$$\begin{aligned} |n(\|\underline{a}(k_n^*)\|_{\hat{R}(k)}^2 - \|\underline{a}(k_n^*)\|_R^2 + \|\underline{a}(k)\|_R^2 - \|\underline{a}(k)\|_{\hat{R}(k)}^2)| \\ \leq n \|\underline{a}(k_n^*) - \underline{a}(k)\|^2 \|\hat{R}(k) - R(k)\| \\ + 2n |(\underline{a}(k_n^*))'(\hat{R}(k) - R(k))(\underline{a}(k))| \end{aligned}$$

よって

$$\begin{aligned} E(n(\underline{a}(k_n^*))'(\hat{R}(k) - R(k))(\underline{a}(k)))^2 \\ \leq \text{const. } n \|\underline{a}(k_n^*) - \underline{a}(k)\|_R |\underline{a}(k) - \underline{a}(k_n^*)| \end{aligned}$$

と評価され、 $k_n^* > k$  のときも同様に評価される。したがって

$$|\underline{a}(k) - \underline{a}(k_n^*)| = \sum_{i=1}^{\max(k, k_n^*)} |\underline{a}_i(k) - \underline{a}_i(k_n^*)|.$$

一方

$$\frac{n \|\underline{a}(k_n^*) - \underline{a}(k_n)\|_R |\underline{a}(k_n) - \underline{a}(k_n^*)|}{(nL_n(k_n))^2}$$

$$\begin{aligned} &\leq \frac{\|a(k_n^*) - a(k_n)\|_R^2}{L_n(k_n)} \frac{\sqrt{\max(k_n^*, k_n)}}{nL_n(k_n)} \\ &\leq \left| \frac{L_n(k_n) - L_n(k_n^*) + \frac{\sigma^2}{n}(k_n^* - k_n)}{L_n(k_n)} \right| \frac{\sqrt{\max(k_n^*, k_n)}}{nL_n(k_n)} \end{aligned}$$

よって,  $k_n^*$  の定義より

$$\frac{\sqrt{\max(k_n^*, k_n)}}{nL_n(k_n)} \rightarrow 0$$

であるから, 結果が従う。  $\square$

以上の結果より, 次の proposition を得る。

Proposition 3.1

lemma 3.1 と同じ仮定のもとに

$$S(k_n^*) - S(k_n) = nL_n(k_n^*)(1 + \delta_n) - nL_n(k_n)(1 + \delta_n')$$

と表わされる。ただし,  $\delta_n, \delta_n'$  は

$$p\text{-}\lim_{n \rightarrow \infty} \delta_n = 0, \quad p\text{-}\lim_{n \rightarrow \infty} \delta_n' = 0$$

なる r. v.

よって, 任意の  $\varepsilon > 0$  に対し

$$\frac{L_n(k)}{L_n(k_n^*)} \leq 1 + \varepsilon$$

なる最小の  $k$  を  $\underline{k}_n^*(\varepsilon)$ , 最大の  $k$  を  $\bar{k}_n^*(\varepsilon)$  とする。



## Theorem 3.1

(A-1) ~ (A-5) の仮定のもとに, 任意の  $\varepsilon > 0$  に対し

$$\lim_{n \rightarrow \infty} \Pr(\underline{k}_n^*(\varepsilon) \leq \hat{k}_n \leq \bar{k}_n^*(\varepsilon)) = 1$$

である。

$$p\text{-}\lim_{n \rightarrow \infty} \frac{L_n(\hat{k}_n)}{L_n(k_n^*)} = 1.$$

Proof.

$\hat{k}_n > \bar{k}_n^*(\varepsilon)$  または  $\hat{k}_n < \underline{k}_n^*(\varepsilon)$  ならば,  $S_n(k)$

の convexity より

$$S_n(k_n^*) \geq S_n(\bar{k}_n^*(\varepsilon) + 1), \quad S_n(\underline{k}_n^*(\varepsilon) - 1)$$

である。proposition 3.1 より

$$\lim_{n \rightarrow \infty} \frac{L_n(\underline{k}_n^*(\varepsilon) - 1)}{L_n(k_n^*)} = 1,$$

$$\lim_{n \rightarrow \infty} \frac{L_n(\bar{k}_n^*(\varepsilon) + 1)}{L_n(k_n^*)} = 1.$$

これは,  $\bar{k}_n^*(\varepsilon)$ ,  $\underline{k}_n^*(\varepsilon)$  の定義に矛盾する。

また,  $\underline{k}_n^*(\varepsilon) \leq \hat{k}_n \leq \bar{k}_n^*(\varepsilon)$  ならば

$$\frac{L_n(\hat{k}_n)}{L_n(k_n^*)} \leq 1 + \varepsilon$$

であるから

$$\lim_{n \rightarrow \infty} \Pr\left(1 \leq \frac{L_n(\hat{k}_n)}{L_n(k_n^*)} \leq 1 + \varepsilon\right) = 1.$$

□

Theorem 3.2 ( $\hat{k}$  の asymptotic efficiency)

(A-1) ~ (A-5) の仮定, および

$$\lim_{\varepsilon \rightarrow 0} \left( \lim_{n \rightarrow \infty} \frac{\bar{k}_n^*(\varepsilon)}{\underline{k}_n^*(\varepsilon)} \right) = 1 \quad (3-1)$$

が成り立つとは

$$p\text{-}\lim_{n \rightarrow \infty} \frac{\|\hat{a}(k_n) - a\|_R^2}{\|\hat{a}(k_n^*) - a\|_R^2} = 1.$$

Proof.

theorem 3.1 の結果, および proposition 2.2 より従う。  $\square$

Example

$\{a_i\}$  が exponentially decreasing sequence ならば,

$$\|\underline{a}(k) - a\|_R^2$$

も同様であり,  $k_n^*$  は  $\log n$  の order  $k$  なる。このとき (3-1) が成り立つ。

## References

1. Akaike, H. (1969). Fitting autoregressive models for prediction. *Ann. Inst. Statist. Math.* 21, 243-247.
2. Akaike, H. (1970). Statistical predictor identification. *Ann. Inst. Statist. Math.* 22, 203-217.
3. Berk, K. N. (1974). Consistent autoregressive spectral estimates. *Ann. Statist.* Vol. 2, No. 3, 489-502.
4. Huzii, M. (1976). On a spectral estimate obtained by an autoregressive model fitting. *Tech. Rep. Dep. of Statist. Stanford Univ.* No. 22.
5. Mallows, C. L. (1973). Some comments on Cp. *Technometrics* 12, 591-612.
6. Shibata, R. (1976). Selection of the order of an autoregressive model by Akaike's information criterion. *Biometrika* 63, 117-126.
7. Shibata, R. (1978). Convergence of least square estimates of autoregressive parameters. to be published in the *Australian Journal of Statistics*, Vol. 20, No. 1.