

## On an ARIMA process

東工大 理 藤井 光昭  
矢島 美寛

### §1. 序

§2, 3 では、Box-Jenkins (4) によって定義された、ARIMA processes の表現および予測について論じる。近年 ARIMA model は応用面において、有効な手段として用いられているが、理論的に明確さを欠く点が見受けられる。ここで、最も簡単な、ARIMA(0, 1, 0) process

$$\nabla X_t \equiv X_t - X_{t-1} = a_t$$

を例にとる。ただし  $E a_t = 0$ ,  $E |a_t|^2 = \sigma_a^2 < \infty$ ,  $E a_t \bar{a}_s = 0$ ,  $t \neq s$ .

Box-Jenkins は、この条件を満たす process として、 $X_{-\infty} = 0$  の仮定のもとで

$$X_t = \sum_{j=0}^{\infty} a_{t-j}$$

のようなものを想定している。しかし右辺の分散は存在せず、等式を i.i.m の意味で解釈することは不可能である。一方  $a_t$  を i.i.d などとして別の収束 (概収束, 確率収束) で理解

することも困難である。たとえ何らかの解釈が可能であるとしても、分散の存在しない process であるから、予測の際には、平均二乗誤差とは別の基準を設けて、予測量の良し悪しを論じなければならぬ。

そこで §2 では、ARIMA( $P, d, \theta$ ) processes の定義を、 $d$  分散有限の processes で  $d$  回差分を取った時、AR-MA( $P, \theta$ ) processes となるものとし、この定義のもとでの processes の一般的表現を求め、

§3 では §2. において求めた表現をもつ processes については、従来の Box-Jenkins の予測量は、平均二乗誤差を最小にするという基準のもとでは最良であることを示す。

§4 以下では、AR processes と MA processes のスペクトル密度関数の特徴づけを試みる。

## §2. ARIMA processes の表現について

まず、いくつかの仮定、記号および定義を導入する。

$$(A1) \quad E\chi_t = 0, \quad E|\chi_t|^2 < \infty, \quad \forall t.$$

$$(W1) \quad \mathfrak{H}(\chi) = \mathfrak{O}\{\chi_t; t=0, \pm 1, \dots\},$$

$$\mathfrak{H}(\chi, t) = \mathfrak{O}\{\chi_s; s \leq t\}.$$

ただし  $\mathfrak{O}$  は  $\{\}$  の中の変数によって生成される Hilbert 空間を表わす。

(N2)  $P_{\mathcal{D}(X,t)}$ , Projection on  $\mathcal{D}(X,t)$ .

(D1) (A1) を満たす process  $X_t$  の innovation (定常過程においては white noise) を,

$$a_t = X_t - P_{\mathcal{D}(X,t-1)} X_t$$

で定義する。(cf. Crámer [5]).

(D2) "Backward Shift operator",  $B$  "Difference operator",  $\nabla$  を

$$B X_t = X_{t-1},$$

$$\nabla X_t = (1-B) X_t = X_t - X_{t-1}, \quad \forall t$$

で定義する。

(A1) の条件のもとで次の定理を得る。

### 定理 1

$X_t$  が ARIMA process となるとき

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) \nabla^d X_t = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) a_t$$

ただし (i)  $a_t = \int_{-\pi}^{\pi} e^{it\lambda} d\tilde{Z}(\lambda)$ ,  $\tilde{Z}(\lambda)$ ; orthogonal random measure

$$E |d\tilde{Z}(\lambda)|^2 = \frac{d\lambda}{2\pi}$$

$$(ii) \phi(B) \equiv 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p \quad (\phi_p \neq 0)$$

$$\theta(B) \equiv 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q \quad (\theta_q \neq 0)$$

$\phi(z)=0$ ,  $\theta(z)=0$ , の根はすべて単位円の外

と表現されるための必要十分条件は、 $X_t$  が次の表現をもつことである。

$$X_t = \int_{-\pi}^{\pi} e^{it\lambda} c(\lambda) dZ(\lambda) + \sum_{j=0}^{d-1} t^j \int_{-\pi}^{\pi} g_j(\lambda) dZ(\lambda) + \sum_{j=0}^{d-1} t^j \cdot \xi_j \quad (2.1)$$

$$\text{ただし (iii) } dZ(\lambda) = \frac{\Theta(e^{-\lambda})}{\Phi(e^{-\lambda})} \cdot d\tilde{Z}(\lambda),$$

$$(iv) \quad C(t, \lambda) = \begin{cases} \sum_{j=0}^{t-1} e^{-\lambda j} \left( \sum_{k_1=1}^{d-1} \dots \sum_{k_2=1}^{k_3} \sum_{k_1=1}^{k_2} \dots \right) & t > 0 \\ (-1)^d \sum_{j=d}^{t+d-1} e^{-\lambda j} \left( \sum_{k_1=1}^{d-(d-1)} \dots \sum_{k_2=1}^{k_3} \sum_{k_1=1}^{k_2} \dots \right) & t \leq 0 \end{cases}$$

ここで  $d=1$  の時、( ) 内は 1 とする。また

$t \leq 0$  において  $|t| < d$  のときは  $C(t, \lambda) = 0$  とする

$$(v) \quad g_j(\lambda) \in L^2(F) \quad \text{と} \quad \tau \cdot \tau \cdot dF(\lambda) = E|dZ(\lambda)|^2 \quad \nu_j,$$

$$(vi) \quad \xi_j \in L^2(\Omega, P),$$

$$\xi_j \perp \mathcal{L}(\nabla^d X) = \left\{ \int_{-\pi}^{\pi} h(\lambda) dZ(\lambda); \int_{-\pi}^{\pi} |h(\lambda)|^2 dF(\lambda) < \infty \right\}.$$

(証明の概略)

(十分性) 明らか

(必要性) もし異なる 2 つの processes が

$$\nabla^d X_t = \int_{-\pi}^{\pi} e^{-it\lambda} dZ(\lambda),$$

$$\nabla^d Y_t = \int_{-\pi}^{\pi} e^{-it\lambda} dZ(\lambda),$$

を満たすとする。すると

$$\nabla^d (X_t - Y_t) \equiv 0$$

したがって一般の ARIMA process は

$$\nabla^d Y_t = \int_{-\pi}^{\pi} e^{-it\lambda} dZ(\lambda) \text{ の特殊解と}$$

$$\nabla^d W_t \equiv 0 \quad \text{の一般解の}$$

和  $X_t = Y_t + W_t$  となる。  $W_t$  は確率変数を係数とする  $t$  の  $(d-1)$  次  
の多項式となる。一方特殊解を求める際には、  $Y_t$  を Oscillatory  
process (Mandrekur [7], Priestley [8])

$$y_t = \int_{-\pi}^{\pi} e^{it\lambda} \cdot C(t, \lambda) dZ(\lambda),$$

$$\text{ただし } C(t, \lambda) \in L^2(F), \forall t$$

と仮定し、 $C(t, \lambda)$  の関数形を求める問題に帰着させる。□

与 (2.1) において

$$y_t = \int_{-\pi}^{\pi} e^{it\lambda} \cdot C(t, \lambda) dZ(\lambda)$$

$$w_t = \sum_{j=0}^{d-1} t^j \cdot \left( \int_{-\pi}^{\pi} g_j(\lambda) dZ(\lambda) + \zeta_j \right)$$

であり、 $w_t$  は "stochastic trend" を表わす部分と言える。(ただし  $\int_{-\pi}^{\pi} g_j(\lambda) dZ(\lambda) + \zeta_j \in \bigwedge_t \mathcal{F}(X, t)$  とは一般には言えない。) ことで見易くするため、 $y_t$  の部分に着目し、time-domain で表現した简单な例を与える。

ex.1  $\nabla X_t = a_t \quad (0, 1, 0)$

$$y_t = \begin{cases} \sum_{u=1}^t a_u & t > 0 \\ 0 & t = 0 \\ -\sum_{u=t+1}^0 a_u & t < 0 \end{cases}$$

ex.2  $(1 - \phi B) \nabla X_t = a_t \quad (1, 1, 0)$

$$y_t = \begin{cases} \sum_{u=1}^t \sum_{j=-\infty}^0 \phi^j a_{u-j} & t > 0 \\ 0 & t = 0 \\ -\sum_{u=t+1}^0 \sum_{j=-\infty}^0 \phi^j a_{u-j} & t < 0 \end{cases}$$

### Remark 1.

(2.1) において  $t > 0$  の場合を例にとると、

$$y_t = \begin{cases} \int_{-\pi}^{\pi} e^{it\lambda} \cdot \frac{(1 - e^{i(t+1)\lambda})}{(1 - e^{i\lambda})} \cdot \frac{(1 - \theta_1 e^{i\lambda} - \dots - \theta_p e^{ip\lambda})}{(1 - \phi_1 e^{i\lambda} - \dots - \phi_p e^{ip\lambda})} \cdot dZ(\lambda) & d=1 \\ \int_{-\pi}^{\pi} e^{it\lambda} \cdot \frac{(1 - (t+1)e^{i\lambda} + te^{i(t+1)\lambda})}{(1 - e^{i\lambda})^2} \cdot \frac{(1 - \theta_1 e^{i\lambda} - \dots - \theta_p e^{ip\lambda})}{(1 - \phi_1 e^{i\lambda} - \dots - \phi_p e^{ip\lambda})} dZ(\lambda) & d=2 \end{cases}$$

つまり ARIMA process を強いて、 $(1-e^{-i\lambda})^d$  を分母に持つスペクトラル表現でしめせば、分子には  $(1-e^{-i\lambda})^d$  を因数とする time-dependent 関数が現われることになる。

### §3. ARIMA processes の予測について

ARIMA processes は、time-domain において

$$X_{t+l} = \varphi_1 X_{t+l-1} + \dots + \varphi_{p+d} X_{t+l-p-d} + a_{t+l} - \theta_1 a_{t+l-1} - \dots - \theta_k a_{t+l-k},$$

あるいは

$$X_{t+l} = \sum_{j=1}^{\infty} \pi_j X_{t+l-j} + a_{t+l} \quad \left( \sum_{j=1}^{\infty} \pi_j = 1 \right)$$

となる。今  $\{X_{t+j}\}$  を  $E_x[X_{t+j}]$ 、すなわち時点  $t$  からの wide-sense conditional expectation とする。Box-Jenkins では、現時点  $t$  から  $l$ -step 先の値  $X_{t+l}$  に対する最良の予測量  $\hat{X}_t(l)$  は

$$\hat{X}_{t+l} = [X_{t+l}] = \varphi_1 [X_{t+l-1}] + \dots + \varphi_{p+d} [X_{t+l-p-d}] + [a_{t+l}] - \dots - \theta_k [a_{t+l-k}] \quad (3.1)$$

あるいは

$$\hat{X}_{t+l} = [X_{t+l}] = \sum_{j=1}^{\infty} \pi_j [X_{t+l-j}] + [a_{t+l}]$$

で与えられている。ここで  $[X_{t+j}]$  は次の規則に従うとされている。

$$[X_{t-j}] = E_x[X_{t-j}] = X_{t-j} \quad j=0, 1, 2, \dots$$

$$[X_{t+j}] = E_x[X_{t+j}] = \hat{X}_t(j) \quad j=1, 2, \dots$$

$$[a_{t-j}] = E_x[a_{t-j}] = a_{t-j} \quad j=0, 1, 2, \dots$$

$$[a_{t+j}] = E_x[a_{t+j}] = 0 \quad j=1, 2, \dots \quad (\text{cf. [4] Ch. 5})$$

しかし定理 1 で表現を求めた process については、必ずしも

$$\{a_{t+j}\} = E_x[a_{t+j}] = 0 \quad j=1, 2, \dots$$

は成立しない。wide-sense conditional expectation とは、Hilbert 空間における Projection を意味する。したがって射影させる部分空間を明確にする必要があるが、予測理論において通常その空間は、過去および現在の変数によって生成される  $\mathcal{H}(x, t)$  である。よって、その場合には  $P_{\mathcal{H}(x, t)} a_{t+j} = 0 (j > 0)$  とは必ずしも言えない。何故なら  $a_t, t=0, \pm 1, \dots$  は  $\nabla^d x_t$  の innovation process であって、 $x_t$  のそれではないからである。換言すれば  $\mathcal{H}(\nabla^d x, t) \subset \mathcal{H}(x, t)$  であるから、 $P_{\mathcal{H}(\nabla^d x, t)} a_{t+j} = 0 (j > 0)$  は成立しても、 $P_{\mathcal{H}(x, t)} a_{t+j} = 0$  とは断定できないわけである。ここで現時点を  $t=0$  とすれば、 $l$ -step 先の値  $x_l$  の最良の予測量は

$$\begin{aligned} \hat{x}_0(l) = P_{\mathcal{H}(x, 0)} x_l &= \varphi_1 P_{\mathcal{H}(x, 0)} x_{l-1} + \dots + \varphi_{l-d} P_{\mathcal{H}(x, 0)} x_{l-d} \\ &+ P_{\mathcal{H}(x, 0)} a_l - \theta_1 P_{\mathcal{H}(x, 0)} a_{l-1} - \dots - \theta_d P_{\mathcal{H}(x, 0)} a_{l-d} \quad (3.2) \end{aligned}$$

となる。その際  $P_{\mathcal{H}(x, 0)} a_j$  は以下のような修正を要する。

### 定理 2.

$$(3.2) \text{ において } P_{\mathcal{H}(x, 0)} a_j = a_j \quad j \leq 0$$

$$P_{\mathcal{H}(x, 0)} a_j = P_{\mathcal{H}\{x_0, x_{-1}, \dots, x_{-d+1}\}} a_j \quad j > 0$$

ここで  $\{x_0, x_{-1}, \dots, x_{-d+1}\}$  は変数列  $\{\dots, a_{-d}, \dots, a_{-2}, a_{-1}, a_0, x_{-d+1}, x_{-d+2}, \dots, x_{-1}, x_0\}$  を直交化した列  $\{\dots, a_{-d}, \dots, a_{-2}, a_{-1}, a_0, x_{-d+1}, \dots, x_{-1}, x_0\}$  の最後の  $d$  個の項とする。

[証明の概略]

(2.1)において  $\eta_j = \int_{-\pi}^{\pi} g_j(\lambda) dZ(\lambda) + \xi_j$ ,  $j=0, \dots, d-1$  とおく。

すると一般の ARIMA process は

$$X_t = \begin{cases} \sum_{u=-\infty}^0 \psi_{t-u} a_{t-u} + \sum_{j=0}^{d-1} t^j \cdot \eta_j, & t > 0, \\ 0 + \sum_{j=0}^{t-1} t^j \cdot \eta_j, & t = 0, -1, \dots, -d+1, \\ \sum_{u=-\infty}^0 \psi_{t-u} a_{t-u} + \sum_{j=0}^{t-1} t^j \cdot \eta_j, & t \leq -d. \end{cases}$$

ここで

$$\begin{aligned} \mathfrak{L}(X, 0) &= \mathfrak{L}\{\dots, a_{-t}, \dots, a_{-1}, a_0, X_{-d+1}, \dots, X_{-1}, X_0\} \\ &= \mathfrak{L}(a, 0) \oplus \mathfrak{L}\{X'_{-d+1}, \dots, X'_{-1}, X'_0\} \end{aligned}$$

を言う。

$$(i) \quad \mathfrak{L}(X, 0) \supset \mathfrak{L}(\nabla^d X, 0) \supset \{\dots, a_{-t}, \dots, a_{-1}, a_0\}$$

$$(ii) \quad \mathfrak{L}(X, 0) \subset \mathfrak{L}\{\dots, a_{-t}, \dots, a_{-1}, a_0, \eta_{d+1}, \dots, \eta_1, \eta_0\}$$

$$\mathfrak{L}\{\eta_{d+1}, \dots, \eta_1, \eta_0\} = \mathfrak{L}\{X'_{-d+1}, \dots, X'_{-1}, X'_0\}$$

を各々用いる。

$$\therefore P_{\mathfrak{L}(X, 0)} a_j = P_{\mathfrak{L}(a, 0)} a_j + P_{\mathfrak{L}\{X'_{-d+1}, \dots, X'_{-1}, X'_0\}} a_j \quad \square$$

定理2の証明から、Box-Jenkinsの方法では stochastic trend 部分が持つ情報を無視して予測量を構成していることがわかる。したがって stochastic trend を持たないような(少なくとも、任意の  $\lambda$  で  $\int_{-\pi}^{\pi} g_j(\lambda) dZ(\lambda) \in \mathfrak{L}(a, 0)$ ) であるような process では、彼等の予測量は最良となるが、そのような仮定はモデルをかなり制限することになる。

ここで今後の統計的存問題について、二、三考察する。まず  $P_{\{X_{t+1}, \dots, X_t, X_0\}} a_j (j > 0)$  の項を評価することに困難を伴う。

ら  $d=1$  とする。すると

$$\begin{aligned} X_0' &= X_0 - \sigma_a^{-2} \cdot \sum_{i=-\infty}^0 E(X_0 \bar{a}_i) a_i \\ P_{\{X_0\}} &= \frac{E(a_i X_0')}{E|X_0'|^2} \cdot X_0' \\ &= \frac{E(a_i \bar{X}_0)}{E|X_0 - \sigma_a^{-2} \cdot \sum_{j=-\infty}^0 (X_0 \bar{a}_j) a_j|^2} \cdot X_0' \end{aligned} \quad (3.3)$$

(3.3)において、 $X_0'$  および  $E|X_0'|^2$  は  $\{X_t, t \leq 0\}, \{R(t, s), t \leq 0, s \leq 0\}$ .

$(R(t, s) \equiv E X_t \bar{X}_s)$  によって表現可能であるが  $E(a_i \bar{X}_0)$  は、時点  $j$  までの covariance に依存する。したがって時点  $t=0$  からこの項を評価するには、process に関する事前情報が必要となる。一方特定の  $t, s$  に対して  $R(t, s)$  は定常の場合と異なり  $R(t, s) \neq R(t-s)$  であるから、こゝでも process の構造に仮定をおかなければ、 $E(X_0 \bar{a}_j) (j < 0)$ ,  $E|X_0'|^2$  の良い推定量を得ることはできない。

また根本的存問題として、実際には有限個の観測値を用いて予測をしなければならぬ。この時、定常過程においても AR-MA モデルと infinite AR モデルのいつれを選択すべきかの問題が生じる。その議論は非定常存過程についても考慮する必要がある。ら  $X_0, X_1, \dots, X_{m+1}$  の値が与えられたとする。  $X_1$  の値を予測するひとつの方法は、

$$E|X_1 - (\alpha_0 X_0 + \alpha_1 X_{-1} + \dots + \alpha_{m-1} X_{-m+1})|^2$$

を最小にする  $(\alpha_0, \alpha_1, \dots, \alpha_{m-1})$  を求めるものである。これらの係数は、定常過程の Yule-Walker equation に対応する、

$$R(1,0) = \alpha_0 R(0,0) + \alpha_1 R(-1,0) + \dots + \alpha_{m-1} R(-m+1,0)$$

$$R(1,-1) = \alpha_0 R(0,-1) + \alpha_1 R(-1,-1) + \dots + \alpha_{m-1} R(-m+1,-1)$$

$$R(1,-m+1) = \alpha_0 R(0,-m+1) + \alpha_1 R(-1,-m+1) + \dots + \alpha_{m-1} R(-m+1,-m+1)$$

を解いて求めることができる。しかしこの方程式に推定量  $\hat{R}(t,s)$  を代入して  $\alpha_i$  を導く時、 $\hat{R}(t,s)$  の推定に関する障害は、上に述べたとおりである。一方 (3.1) 式を用いる場合、過去の innovation  $a_j (j \leq 0)$  を求めることさえ難しい。Box-Jenkins では  $a_j = 0$  として、予測値を計算している。しかしこの方法を用いるとこれは、 $P_{\{x_{-d+1}, \dots, x_{-1}, x_0\}} a_j (j > 0)$  を評価する意味はない。そこでまず  $a_j (j \leq 0)$  を求めることが必要だが、そのためには infinite AR 表現に、inversion し、

$$x_t - \sum_{j=1}^{\infty} \pi_j x_{t-j} = a_t$$

を用いる。今、データは  $x_0, x_{-1}, \dots, x_{-m+1}$  だけであるから、 $\pi_j$  の 0 への収束が非常に遅い時、誤差の分散（かりに  $a=0$  とすれば、 $-\sum_{j=m}^{\infty} \pi_j x_{-j}$  の分散）は大きくなる。これに比して  $P_{\{x_{-d+1}, \dots, x_{-1}, x_0\}} a_j (j > 0)$  の分散が小さければ、この項を評価する意義はうたれる。したがって応用上では、この二つの量の比較をまず考えなければならぬ。

#### § 4. AR process と MA process のスペクトル密度関数の

##### ある表現

ARMA モデルのあてはめをおこなおうとするとき  $(p+q)$  個の係数を用いてモデルを表現するにしても,  $AR(p+q)$ ,  $MA(p+q)$ ,  $ARMA(p, q)$  というモデルとあてはめることが可能であり, どれを用いるのが良いかはその目的や問題とする定常過程の構造によって異なるであろう。ここではスペクトル密度の推定という目的に限定することにし, 上に述べた問題と論じるための一つの試みをおこなう。本来この問題は推定論上の観点も含めて論ずべきであると考えられるが, ここではその第一段階として  $AR$  モデルと  $MA$  モデルを分離して考え, それぞれから得られるスペクトル密度関数の特徴を論じることとする。

以下において  $x_t$  は  $Ex_t = 0$ ,  $Ex_{t+h} \bar{x}_t = R_h$  であるような弱定常過程とし, 前節までと同様に

$$x_t = \int_{-\pi}^{\pi} e^{it\lambda} dZ(\lambda)$$

とあらわされているものとする。

いま,  $x_t$  が  $p$  次の  $AR$  process である と仮定すれば "white noise"  $a_t$  を用いて

$$\sum_{j=0}^p (-\phi_j) x_{t-j} = a_t \quad (\phi_0 = -1)$$

のように表わされ,  $x_t$  のスペクトル密度関数  $f(\lambda)$  は

$$f(\omega) = \sigma_a^2 / (2\pi |\phi(e^{-i\omega})|^2)$$

であるが  $\phi(B^{-1})=0$  の根を  $-\alpha_j$  ( $1 \leq j \leq p$ ,  $|\alpha_j| < 1$ ) とおくと

$$\phi(e^{-i\omega}) = \prod_{j=1}^p (1 + \alpha_j e^{-i\omega})$$

とあらわすことができる。これから  $f(\omega)$  の特徴と推定を論じるために都合のよい  $f(\omega)$  の表現を求めることにする。

任意な弱定常過程  $y_t$  ( $E y_t = 0$ ) に対し operator  $D(\alpha)$  を

$$D(\alpha) y_t = (1 + \alpha B) y_t = y_t + \alpha y_{t-1}$$

と定義する。このとき  $p$  次の AR process  $x_t$  は

$$D(\alpha_1) D(\alpha_2) \cdots D(\alpha_p) x_t = a_t$$

とあらわすことができる。いま

$$y_t^{(j)} = D(\alpha_{j+1}) D(\alpha_{j+2}) \cdots D(\alpha_p) x_t \quad (0 \leq j \leq p-1)$$

とおくと,  $y_t^{(j)}$  も平均値 0 である弱定常過程となる。  $(\sigma^{(j)})^2 = \text{Var}(y_t^{(j)})$  とおくと

$$(\sigma^{(j)})^2 = (\sigma^{(j+1)})^2 (1 + |\alpha_{j+1}|^2 + 2 \text{Real} \bar{\alpha}_{j+1} \rho^{(j+1)})$$

となる。ただし  $\rho^{(j+1)} = E y_t^{(j+1)} \bar{y}_{t-1}^{(j+1)} / E |y_t^{(j+1)}|^2$ ,  $\rho^{(p)} = R_1 / R_0$ ,  $\sigma^{(0)} = \sigma_a$ ,  $\rho^{(1)} = -\alpha_1$ ,  $(\sigma^{(p)})^2 = R_0$  である。

この条件のもとで  $y_t^{(j)}$  は purely non-deterministic になり,  $|\rho^{(j)}| < 1$  ( $1 \leq j \leq p$ ) となる。また  $\rho^{(j)}$  は  $\alpha_1, \alpha_2, \dots, \alpha_j$  のみの関数となる。

以上により次の結果が得られる。

定理 3.  $p$  次の AR process  $x_t$  のスペクトル密度関数  $f(\omega)$

は

$$f(\omega) = R_0 \prod_{j=1}^p (1 + |\alpha_j|^2 + 2 \operatorname{Re} \bar{\alpha}_j e^{-i\omega}) / \prod_{j=1}^p |1 + \alpha_j e^{-i\omega}|^2$$

とあらわすことができる。

上の表現はモデルのあてはめのためであり、 $x_t$  が与えられてその分散  $R_0$  は一定にしておき、 $p$  を変化させるたびに  $\alpha_j$  が  $\sigma^2$  white noise の分散  $\sigma_a^2$  をそれに合わせてかえていくというものである。

つぎに  $x_t$  が  $\delta$  次の MA process であるとする。このとき

$$x_t = \sum_{j=0}^{\delta} (-\theta_j) a_{t-j} \quad (\theta_0 = -1)$$

のようにならわされ、 $x_t$  のスペクトル密度関数  $f(\omega)$  は

$$f(\omega) = (\sigma_a^2 / 2\pi) |\theta(e^{-i\omega})|^2$$

であるが、 $\theta(B^{-1}) = 0$  の根を  $-\beta_j$  ( $1 \leq j \leq \delta$ ,  $|\beta_j| < 1$ )

とおくと

$$\theta(e^{-i\omega}) = \prod_{j=1}^{\delta} (1 + \beta_j e^{-i\omega})$$

とあらわすことができる。

このとき

$$x_t = D(\beta_1) D(\beta_2) \cdots D(\beta_{\delta}) a_t$$

とあらわされる。いま

$$x_t^{(j)} = D(\beta_{j+1}) D(\beta_{j+2}) \cdots D(\beta_{\delta}) a_t \quad (0 \leq j \leq \delta - 1)$$

とおくと,  $\gamma_t^{(j)}$  は平均値0である弱定常過程になる。  $(\sigma_\gamma^{(j)})^2 = \text{Var}(\gamma_t^{(j)})$  とおくと,

$$(\sigma_\gamma^{(j)})^2 = (\sigma_\gamma^{(j+1)})^2 (1 + |\beta_{j+1}|^2 + 2 \text{Re} \bar{\beta}_{j+1} \gamma^{(j+1)})$$

となる。ただし  $(\sigma_\gamma^{(0)})^2 = R_0$ ,  $\gamma_t^{(0)} = a_t$ ,  $(\sigma_\gamma^{(0)})^2 = \sigma_a^2$ ,  $\gamma^{(j+1)} = E \gamma_t^{(j+1)} \bar{\gamma}_{t-1}^{(j+1)} / E |\gamma_t^{(j+1)}|^2$  である。

上の条件のもとで  $\gamma_t^{(j)}$  は purely nondeterministic process となり,  $|\gamma^{(j)}| < 1$  ( $1 \leq j \leq \xi$ ) となる。また  $\gamma^{(j)}$  は  $\beta_{j+1}, \beta_{j+2}, \dots, \beta_\xi$  のみの関数である。

以上により次の結果が得られる。

定理4  $\xi$  次の MA process  $x_t$  のスペクトル密度関数  $f(\omega)$  は

$$f(\omega) = (R_0/2\pi) \prod_{j=1}^{\xi} |1 + \beta_j e^{-i\omega}|^2 / \prod_{j=1}^{\xi} (1 + |\beta_j|^2 + 2 \text{Re} \bar{\beta}_j \gamma^{(j)})$$

とあらわすことができる。

この表現も  $x_t$  が与えられ  $R_0$  が与えられたという形である。いま  $a_t \in \text{white noise}$  で  $\sigma_a^2 > 0$  とする。このとき任意な  $\beta_j$  に対して  $(\sigma_\gamma^{(j)})^2 = E |a_t + (\sum \beta_i) a_{t-1} + \dots|^2 \geq \sigma_a^2 > 0$  となり,  $(\sigma_\gamma^{(j)})^2 > 0$  ( $0 \leq j \leq \xi-1$ ) が成り立つ。

## § 5. スペクトル密度関数の特徴

§4 において求めた AR process または MA process のスペクトル密度関数の分解した形での表現を用いてその特徴を調べることにする。この分解により特徴は各要素ごとに調べることにする。

(i)  $\alpha_i$  または  $\beta_i$  が実数のとき

AR process に対して

$$f_i^A(\lambda) = (1 + |\alpha_i|^2 + 2 \operatorname{Re} \alpha_i \rho^{(i)}) / |1 + \alpha_i e^{-i\lambda}|^2$$

とおく。  $\alpha_i < 0$  のとき  $f_i^A(\lambda)$  は単調減少。  $\rho^{(i)} = -\alpha_i$  であるから

より  $f_i^A(\lambda) = (1 - \alpha_i^2) / (1 + \alpha_i^2 + 2\alpha_i \cos \lambda)$  となる。従って

$$\lim_{\alpha_i \rightarrow -1} f_i^A(\lambda) = \begin{cases} +\infty & ; \lambda = 0 \\ 0 & ; \lambda \neq 0 \end{cases}$$

となる。  $\alpha_i > -1$  のとき  $f_i^A(0)$  は有界。  $f_i^A(0) \neq 0$ 。故に  $\alpha_i$  を

$-1$  に近く選ぶことにより  $f(0)$  はいくらでも大きな値をとることができる。  $\delta$  関数のようなスペクトル密度の達成可能である。

$\alpha_i > 0$  のときには  $f_i^A(\lambda)$  は単調増加で  $\lambda = \pi$  において上と同じ議論が成り立つ。

MA process に対しては  $\sigma_\alpha^2 \leq R_0$  であるから  $|\beta_i| \leq 1$  である限りどのように  $\beta_i$  を選んでも  $f(\lambda)$  は有界である。いま

$$f_i^M(\lambda) = |1 + \beta_i e^{-i\lambda}|^2$$

とおくと、  $f_i^M(\lambda)$  は  $\beta_i > 0$  のとき単調減少で  $\beta_i < 0$  のとき単調増加。  $\beta_i \rightarrow 1$  (または  $-1$ ) のとき  $\lambda = \pi$  (または  $0$ ) で  $0$  に

逆の値をとる。

(ii)  $d_j$  または  $\beta_j$  が複素数のとき

AR process について考える。  $d_j$  が  $\phi(B^{-1}) = 0$  の根なら  $\bar{d}_j$  も根である。いま  $d_j' = \bar{d}_j$  とし、

$$g_j^A(\lambda) = f_j^A(\lambda) f_j'^A(\lambda) \\ = \frac{(1 + |d_j|^2 + 2 \operatorname{Re} d_j f^{(j)}) (1 + |\bar{d}_j|^2 + 2 \operatorname{Re} \bar{d}_j f^{(j)})}{|1 + d_j e^{-i\lambda}|^2 |1 + \bar{d}_j e^{-i\lambda}|^2}$$

とおく。このとき  $g_j^A(\lambda)$  の分母は  $S_1^2 (\cos \lambda + S_2)^2 + S_3$  という形に書ける。ただし  $S_1 = 2|d_j|$ ,  $S_2 = (1 + |d_j|^2) u_j / (2|d_j|^2)$ ,  $S_3 = v_j^2 (1 - |d_j|^2)^2 / |d_j|^2$  である。ここで  $d_j = u_j + i v_j$  ( $u_j, v_j$  は実数) とおいた。類似の表現は [3] にも求められている。 $g_j^A(\lambda)$  の最大値をとる  $\lambda$  の値  $\lambda_0$  が  $u_j$  と  $v_j$  の値により  $0 < \lambda_0 < \pi$  となる。そして

$$\lim_{|d_j| \rightarrow 1} g_j^A(\lambda_0) = 1/v_j^2, \quad \lim_{|d_j| \rightarrow 1} g_j^A(\lambda) = 0 \quad (\lambda \neq \lambda_0)$$

となり  $v_j \rightarrow 0$  とすることにより  $g_j^A(\lambda_0)$  はいくらでも大きな値をとり  $\lambda = \lambda_0$  でのラインスペクトルに近いものを達成することが可能である。

$$\lim_{|d_j| \rightarrow 0} g_j^A(\lambda) = 1$$

で white noise に対応する。

MA process についても同様に

$$g_j^M(\lambda) = |1 + \beta_j e^{-i\lambda}|^2 |1 + \bar{\beta}_j e^{-i\lambda}|^2$$

とかくと

$$g_j^M(\lambda) = T_1^2 (\cos \lambda + T_2)^2 + T_3$$

とあらわされる。ここで  $T_1, T_2, T_3$  はそれぞれ  $S_1, S_2, S_3$  において  $d_j \in \beta_j$ ,  $u_j \in \text{Recl } \beta_j$ ,  $v_j \in \text{Imag } \beta_j$  でおきかえたものである。 $g_j^M(\lambda)$  は  $|\beta_j| \leq 1$  において有界であり、 $I, \cos \lambda, \cos 2\lambda$  で張られる線形空間内にある。 $|T_2| \leq 1$  のとき  $\cos \lambda = -T_2$  とする  $\lambda_0$  で最小値をとる、その他のときは  $0$  または  $\pi$  で最小値をとる。最大値は  $0$  か  $\pi$  でとる。そして

$$\lim_{|\beta_j| \rightarrow 0} g_j^M(\lambda) = I$$

となり white noise に対応する。

AR process や MA process の自己相関係数の性質が [1], [2], [6] などで論じられているが、ここでも上の議論を更に発展させて AR モデルのあてはめと MA モデルのあてはめのそれぞれの特徴および推定量の性質も考慮に入れた議論を将来展開したいものと考えている。パラメータの数を一定にしておいた上での AR モデルによる達成可能な  $f(\lambda)$  の族と MA モデルにより達成可能な  $f(\lambda)$  の族、**ARMA** モデルによって達成される  $f(\lambda)$  の族の関係、それぞれのモデルにおけるパラメータ数と推定量の分散の関係、および平均と乗設差との関係等が今後の問題である。

## References

- [1] Anderson, O. D., (1975), The recursive nature of the stationarity and invertibility restraints on the parameters of mixed autoregressive-moving average processes, *Biometrika*, 62, 704-706.
- [2] Anderson, O. D., (1976), On two convex autocorrelation regions for moving average processes, *Biometrika*, 63, 681-683.
- [3] Anderson, T. W., (1971), *The statistical analysis of time series*, John Wiley & Sons, Inc., New York.
- [4] Box, G.E.P. & Jenkins, G. M., (1970), *Time series analysis and forecasting and control*, Holden Day, San Francisco.
- [5] Crámer, H., (1960), On some class of non stationary stochastic processes, *Proc. 4th Berkeley Symp. on Math. Stat. & Prob.* 2, 57-78.
- [6] Davies, N., Pate, M. B. & Frost, M. G., (1974), Maximum autocorrelations for moving average processes, *Biometrika*, 61, 199-200.
- [7] Mandrekar, V., (1968), A characterization of oscillatory process and their prediction, *Proc. Amer. Math. Soc.*, 32, 280-284.
- [8] Priestley, M. B. (1965), Evolutionary spectra and nonstationary processes, *J. R. S. S.*, 25, 153-188.