

# 第 1 章「確率過程と時系列モデル」

## 1 . 確率過程 (Stochastic Process)

確率過程: 時点  $t$  の添字をもつ確率変数  $y_t$  の系列全体のこと .  $\{y_t\}$  で表す .

- (a) 離散的確率過程 : 時点  $t$  の集合が可算的な確率過程 ( 通常は ,  $t=1, 2, \dots$  )
- (b) 連続的確率過程 : 時点  $t$  の集合が連続的な確率過程 (  $t$  は実数の集合の点 )

以下では , 主として離散的確率過程を考える .


確率変数と確率過程の違い : 確率過程  $\{y_t\}$  において , 各時点  $t$  を固定すれば時点  $t$  における確率変数  $y_t$  となる . ただし , 確率過程からの  $n$  個のデータ  $y_1, \dots, y_n$  は各時点から 1 個ずつ得られるものである .

確率過程の期待値と分散

$$E(y_t) = \mu_t, \quad V(y_t) = \sigma_t^2$$

のように , 時点  $t$  における期待値と分散は  $t$  に依存してもよい ( 非定常過程 ) . しかし , 各時点からデータが 1 個しか得られないので ,  $\mu_t$  や  $\sigma_t^2$  を推定することは無意味となる . ただし , モデルを特定化すれば推定可能である ( ランダム・ウォークモデル , ARCH モデルなど ) . 以下では , モデルを導入する前に , まず ,  
⇒ 確率過程のクラスを制限して考える .

*Realization of AR(2) process*



## 2 . 定常過程 (Stationary Process)

定義： 確率過程  $\{y_t\}$  が定常過程であるとは，

$$E(y_t) = \mu \quad (\text{定数}) \quad \text{Cov}(y_s, y_t) = \gamma_{|s-t|} \quad (\text{時間差のみに依存})$$

となることをいう．このとき，分散は一定となる．

定義：  $\{y_t\}$  が定常過程のとき， $\gamma_h = \text{Cov}(y_t, y_{t-h})$  を時差  $h$  の  $\{y_t\}$  の自己共分散 (Autocovariance) という．また， $\rho_h = \gamma_h / \gamma_0$  を時差  $h$  の自己相関 (Autocorrelation) という．自己相関は測定単位に依存しない無名数であり，自己共分散よりも有用である．

Note:  $\gamma_h = \gamma_{-h}$ ,  $\rho_h = \rho_{-h}$ ,  $\rho_0 = 1$

定義： 自己相関  $\gamma_h$  を  $h$  の関数とみなしたものを自己相関関数 (acf) あるいはコレログラムという．

例 1： 無相関で分散が一定の確率過程 (無相関過程，ホワイト・ノイズ)，すなわち

$$\text{Cov}(y_s, y_t) = \begin{cases} \sigma^2 & (s = t \text{ のとき}) \\ 0 & (s \neq t \text{ のとき}) \end{cases}$$

となる  $\{y_t\}$  は定常過程である．

例 2：  $\{y_t\}$  が  $\text{i.i.d.}(\mu, \sigma^2)$  の列ならば定常である．

(注)  $\text{i.i.d.}(\mu, \sigma^2)$  = 平均  $\mu$ ，分散  $\sigma^2$  の独立，同一分布に従う確率過程

例 3：  $X$  と  $Y$  を互いに無相関で平均 0，分散  $\sigma^2$  の確率変数とし， $\lambda$  を定数とするととき，

$$y_t = X \cos \lambda t + Y \sin \lambda t$$

は定常過程となる．実際， $E(y_t) = 0$  で，

$$\begin{aligned} \gamma_h &= \text{Cov}(y_t, y_{t-h}) = E(y_t y_{t-h}) \\ &= E[(X \cos \lambda t + Y \sin \lambda t)(X \cos \lambda(t-h) + Y \sin \lambda(t-h))] \\ &= \sigma^2 [\cos \lambda t \cos \lambda(t-h) + \sin \lambda t \sin \lambda(t-h)] \\ &= \sigma^2 \cos \lambda h \end{aligned}$$

となる．

## 3 . 定常な時系列モデルの例

以下， $\{\varepsilon_t\} \sim \text{i.i.d.}(0, \sigma^2)$  とする．また， $L$  をラグ・オペレータ  $Ly_t = y_{t-1}$ ， $L^2 y_t = y_{t-2}$ ， $\dots$  として，ラグ多項式

$$\phi(L) = 1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p,$$

$$\theta(L) = 1 - \theta_1 L - \theta_2 L^2 - \dots - \theta_q L^q,$$

を定義しておく .

(A) AR(p) モデル  $\phi(L)y_t = m + \varepsilon_t$

$$y_t = m + \phi_1 y_{t-1} + \cdots + \phi_p y_{t-p} + \varepsilon_t \quad (1)$$

AR(p) モデルの定常性 (Stationarity) の条件 : 特性方程式

$$\phi(x) = 1 - \phi_1 x - \phi_2 x^2 - \cdots - \phi_p x^p = 0$$

の根の絶対値がすべて 1 より大きいこと (= 根がすべて単位円外にあること) .

例 4 :

1. AR(1)  $y_t = m + \phi_1 y_{t-1} + \varepsilon_t$  の定常性 :  $|\phi_1| < 1$

2. AR(2)  $y_t = m + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \varepsilon_t$  の定常性 :  $\phi_2 + \phi_1 < 1, \phi_2 - \phi_1 < 1, -1 < \phi_2 < 1$

定常な AR(p) モデルは MA( $\infty$ ) 表現

$$y_t = \phi(L)^{-1}(m + \varepsilon_t) = \mu + \sum_{j=0}^{\infty} \pi_j \varepsilon_{t-j}, \quad \pi_0 = 1$$

をもつ .

AR(1) の場合:

$$\begin{aligned} y_t &= \frac{1}{1 - \phi_1 L}(m + \varepsilon_t) \\ &= [1 + \phi_1 L + (\phi_1 L)^2 + \cdots](m + \varepsilon_t) \\ &= \frac{1}{1 - \phi_1} m + \sum_{j=0}^{\infty} \phi_1^j \varepsilon_{t-j} \end{aligned}$$

これより ,

$$E(y_t) = \frac{1}{1 - \phi_1} m, \quad \gamma_0 = V(y_t) = \sigma^2 \sum_{j=0}^{\infty} \phi_1^{2j} = \frac{\sigma^2}{1 - \phi_1^2}$$

定常な AR(p) モデルの平均 , 分散とコレログラム

平均の求め方: (1) の両辺の期待値を取ることにより ,

$$\begin{aligned} \mu &= E(y_t) = E(m + \phi_1 y_{t-1} + \cdots + \phi_p y_{t-p} + \varepsilon_t) \\ &= m + \mu(\phi_1 + \cdots + \phi_p) \\ &= \frac{m}{1 - \phi_1 - \cdots - \phi_p} \\ &= \frac{m}{\phi(1)} \end{aligned}$$

Note: このとき, (1) は

$$y_t - \mu = \phi_1(y_{t-1} - \mu) + \cdots + \phi_p(y_{t-p} - \mu) + \varepsilon_t \quad (2)$$

あるいは

$$\phi(L)(y_t - \mu) = \varepsilon_t$$

と表すことができる.

コレログラムの求め方: (2) 式の両辺に  $y_{t-j} - \mu$  ( $j > 0$ ) をかけて期待値を取ると,

$$\gamma_j = \phi_1\gamma_{j-1} + \phi_2\gamma_{j-2} + \cdots + \phi_p\gamma_{j-p}$$

が得られる. そして, 両辺を  $\gamma_0 = V(y_t)$  で割ることにより,

$$\rho_j = \phi_1\rho_{j-1} + \phi_2\rho_{j-2} + \cdots + \phi_p\rho_{j-p} \quad (3)$$

を得る. これは  $p$  階の差分方程式であり, 解くためには  $p$  個の初期値が必要. そのために, (3) において  $j=1, 2, \dots, p$  の場合を考えると, 次の  $p$  本の方程式 (Yule-Walker 方程式) が得られる.

$$\begin{aligned} \rho_1 &= \phi_1 + \phi_2\rho_1 + \cdots + \phi_p\rho_{p-1} \\ \rho_2 &= \phi_1\rho_1 + \phi_2 + \cdots + \phi_p\rho_{p-2} \\ \cdot & \quad \cdot \quad \cdot \quad \cdot \quad \cdot \\ \cdot & \quad \cdot \quad \cdot \quad \cdot \quad \cdot \\ \cdot & \quad \cdot \quad \cdot \quad \cdot \quad \cdot \\ \rho_p &= \phi_1\rho_{p-1} + \phi_2\rho_{p-2} + \cdots + \phi_p \end{aligned}$$

行列表現では

$$R\phi = \rho \Leftrightarrow \begin{pmatrix} 1 & \rho_1 & \cdots & \rho_{p-1} \\ \rho_1 & 1 & \cdots & \rho_{p-2} \\ \vdots & \vdots & \ddots & \vdots \\ \rho_{p-1} & \rho_{p-2} & \cdots & 1 \end{pmatrix} \begin{pmatrix} \phi_1 \\ \cdot \\ \cdot \\ \cdot \\ \phi_p \end{pmatrix} = \begin{pmatrix} \rho_1 \\ \cdot \\ \cdot \\ \cdot \\ \rho_p \end{pmatrix}$$

分散  $\gamma_0$  の求め方: (2) 式の両辺に  $y_t - \mu$  をかけて期待値を取ると,

$$\begin{aligned} \gamma_0 &= \phi_1\gamma_1 + \phi_2\gamma_2 + \cdots + \phi_p\gamma_p + \sigma^2 \\ &= \gamma_0(\phi_1\rho_1 + \phi_2\rho_2 + \cdots + \phi_p\rho_p) + \sigma^2 \end{aligned}$$

が得られる. これより,

$$\gamma_0 = \frac{\sigma^2}{1 - \phi_1\rho_1 - \phi_2\rho_2 - \cdots - \phi_p\rho_p}$$

例 5: AR(1), AR(2) の分散とコレログラム

1. AR(1):  $\rho_1 = \phi_1, \rho_h = \phi_1 \rho_{h-1} = \phi_1^h \ (h \geq 1)$   
 $\gamma_0 = \sigma^2 / (1 - \phi_1 \rho_1) = \sigma^2 / (1 - \phi_1^2)$
2. AR(2):  $\rho_1 = \frac{\phi_1}{1 - \phi_2}, \rho_h = \phi_1 \rho_{h-1} + \phi_2 \rho_{h-2} \ (h \geq 2)$   
 $\rho_2 = \phi_1 \rho_1 + \phi_2 = (\phi_1^2 + \phi_2(1 - \phi_2)) / (1 - \phi_2)$   
 $\gamma_0 = \sigma^2 / (1 - \phi_1 \rho_1 - \phi_2 \rho_2) = (1 - \phi_2) \sigma^2 / [(1 + \phi_2)\{(1 - \phi_2)^2 - \phi_1^2\}]$

**(B) MA(q) モデル**  $y_t = m + \theta(L)\varepsilon_t$

$$y_t = m + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \cdots - \theta_q \varepsilon_{t-q} = m + \theta(L)\varepsilon_t \quad (4)$$

明らかに,  $E(y_t) = m$  である. また,

$$\begin{aligned} \gamma_0 &= V(y_t) = \sigma^2(1 + \theta_1^2 + \cdots + \theta_q^2), \\ \gamma_1 &= Cov(y_t, y_{t-1}) \\ &= E[(\varepsilon_t - \theta_1 \varepsilon_{t-1} - \cdots - \theta_q \varepsilon_{t-q})(\varepsilon_{t-1} - \theta_1 \varepsilon_{t-2} - \cdots - \theta_q \varepsilon_{t-1-q})] \\ &= \sigma^2(-\theta_1 + \theta_1 \theta_2 + \cdots + \theta_{q-1} \theta_q), \\ \gamma_2 &= Cov(y_t, y_{t-2}) \\ &= E[(\varepsilon_t - \theta_1 \varepsilon_{t-1} - \cdots - \theta_q \varepsilon_{t-q})(\varepsilon_{t-2} - \theta_1 \varepsilon_{t-3} - \cdots - \theta_q \varepsilon_{t-2-q})] \\ &= \sigma^2(-\theta_2 + \theta_1 \theta_3 + \cdots + \theta_{q-2} \theta_q), \end{aligned}$$

より,  $\rho_h = 0 \ (h \geq q + 1)$  である. また,  $h = 1, 2, \dots, q$  のとき,

$$\rho_h = \frac{-\theta_h + \theta_1 \theta_{h+1} + \cdots + \theta_{q-h} \theta_q}{1 + \theta_1^2 + \cdots + \theta_q^2}, \quad (h = 1, 2, \dots, q)$$

MA(q) モデルの反転可能性 (Invertibility): MA(q) モデルを AR( $\infty$ ) で表現できること. そのための条件は, 特性方程式

$$\theta(x) = 1 - \theta_1 x - \theta_2 x^2 - \cdots - \theta_q x^q = 0$$

の根の絶対値がすべて 1 より大きいこと (= 根がすべて単位円外にあること).

MA(1) の場合:

$$\begin{aligned} \varepsilon_t &= \frac{1}{1 - \theta_1 L}(y_t - m) \\ &= [1 + \theta_1 L + (\theta_1 L)^2 + \cdots](y_t - m) \\ &= \sum_{j=0}^{\infty} \theta_1^j y_{t-j} - \frac{1}{1 - \theta_1} m \end{aligned}$$

**(C) ARMA(p,q) モデル**  $\phi(L)y_t = m + \theta(L)\varepsilon_t$

$$y_t = m + \phi_1 y_{t-1} + \cdots + \phi_p y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \cdots - \theta_q \varepsilon_{t-q} \quad (5)$$

定常性：  $\phi(x) = 1 - \phi_1x - \phi_2x^2 - \dots - \phi_px^p = 0$  の根がすべて単位円外

反転可能性：  $\theta(x) = 1 - \theta_1x - \theta_2x^2 - \dots - \theta_qx^q = 0$  の根がすべて単位円外

例 6： ARMA(1,1) の MA( $\infty$ ) 表現

$$\begin{aligned} y_t &= \frac{1}{1 - \phi_1 L} (m + (1 - \theta_1 L) \varepsilon_t) \\ &= \frac{1}{1 - \phi_1 L} m + [1 + \phi_1 L + (\phi_1 L)^2 + \dots] (1 - \theta_1 L) \varepsilon_t \\ &= \frac{1}{1 - \phi_1} m + [1 + (\phi_1 - \theta_1) L + \phi_1 (\phi_1 - \theta_1) L^2 + \dots] \varepsilon_t \\ &= \frac{1}{1 - \phi_1} m + \varepsilon_t + (\phi_1 - \theta_1) \sum_{j=0}^{\infty} \phi_1^j \varepsilon_{t-1-j} \end{aligned}$$

したがって，

$$\begin{aligned} E(y_t) &= \frac{1}{1 - \phi_1} m, \quad \gamma_0 = \sigma^2 [1 + (\phi_1 - \theta_1)^2 \sum_{j=0}^{\infty} \phi_1^{2j}] = \sigma^2 \left[ 1 + \frac{(\phi_1 - \theta_1)^2}{1 - \phi_1^2} \right] \\ \gamma_1 &= E \left[ \left( \varepsilon_t + (\phi_1 - \theta_1) \sum_{j=0}^{\infty} \phi_1^j \varepsilon_{t-1-j} \right) \left( \varepsilon_{t-1} + (\phi_1 - \theta_1) \sum_{j=0}^{\infty} \phi_1^j \varepsilon_{t-2-j} \right) \right] \\ &= \sigma^2 [(\phi_1 - \theta_1) + (\phi_1 - \theta_1)^2 \phi_1 (1 + \phi_1^2 + \phi_1^4 + \dots)] \\ &= \sigma^2 \frac{(1 - \phi_1 \theta_1)(\phi_1 - \theta_1)}{1 - \phi_1^2}, \\ \gamma_h &= \phi_1 \gamma_{h-1} \quad (h \geq 2) \end{aligned}$$

#### 4 . 偏自己相関 (Partial Autocorrelation)

定義： 定常過程  $\{y_t\}$  のラグ  $h$  の偏自己相関とは，次の方程式における解  $\phi_{hh}$  のことである．

$$\begin{pmatrix} 1 & \rho_1 & \dots & \rho_{h-1} \\ \rho_1 & 1 & \dots & \rho_{h-2} \\ \vdots & \vdots & \ddots & \vdots \\ \rho_{h-1} & \rho_{h-2} & \dots & 1 \end{pmatrix} \begin{pmatrix} \phi_{h1} \\ \phi_{h2} \\ \vdots \\ \phi_{hh} \end{pmatrix} = \begin{pmatrix} \rho_1 \\ \rho_2 \\ \vdots \\ \rho_h \end{pmatrix}$$

Note: ラグ  $h$  の偏自己相関とは，時点  $t - h$  と時点  $t$  の間に存在する  $h - 1$  個の観測値  $y_{t-h+1}, \dots, y_{t-1}$  の影響を除去したあとの  $y_{t-h}$  と  $y_t$  の相関係数である．

(注) 変数  $x, y, z$  を分析対象とする場合， $x$  と  $y$  の偏相関係数とは， $z$  の影響を除去したあとの  $x$  と  $y$  の相関係数である．

例 7： 定常な AR(p) モデル

$$y_t = m + \phi_1 y_{t-1} + \dots + \phi_p y_{t-p} + \varepsilon_t$$

の偏自己相関は，ラグ  $p$  で切断を生じる．

$$\phi_{11} = \rho_1, \quad \phi_{22} = \frac{\rho_2 - \rho_1^2}{1 - \rho_1^2}, \quad \dots, \quad \phi_{pp} = \phi_p, \quad \phi_{hh} = 0 \quad (h \geq p + 1).$$

例 8 : MA(1) モデル  $y_t = m + \varepsilon_t - \theta_1 \varepsilon_{t-1}$  の偏自己相関は減衰する．

$$\phi_{hh} = \frac{-\theta_1^h}{1 + \theta_1^2 + \theta_1^4 + \dots + \theta_1^{2h}}$$

例 9 : 定常な ARMA(p,q) モデルの偏自己相関は自己相関と同様に切断を生じない．

## 5 . 逆自己相関 (Inverse Autocorrelation)

定義 : 定常，反転可能な ARMA(p,q) 過程  $\phi(L)y_t = m + \theta(L)\varepsilon_t$  におけるラグ  $h$  の逆自己相関とは，ARMA(q,p) 過程  $\theta(L)y_t = m + \phi(L)\varepsilon_t$  におけるラグ  $h$  の自己相関のことである．

例 10 : AR(p) モデルの逆自己相関は，ラグ  $p$  で切断を生じる．

## 5 . AR, MA, ARMA の相互比較 ( $z_t = y_t - \mu$ )

	AR: $\phi(L)z_t = \varepsilon_t$	MA: $z_t = \theta(L)\varepsilon_t$	ARMA: $\phi(L)z_t = \theta(L)\varepsilon_t$
AR 表現	有限列	無限列	無限列
MA 表現	無限列	有限列	無限列
定常性	$\phi(x) = 0$ の根が すべて $ x  > 1$	常に定常	$\phi(x) = 0$ の根が すべて $ x  > 1$
反転可能性	常に反転可能	$\theta(x) = 0$ の根が すべて $ x  > 1$	$\theta(x) = 0$ の根が すべて $ x  > 1$
自己相関	減衰	切断	減衰
偏自己相関	切断	減衰	減衰
逆自己相関	切断	減衰	減衰