

# 第5回 1変量時系列モデルの定式化と推定 (7.1.3, 7.2.2–7.2.3)

村澤 康友

2020年10月27日

## 今日のポイント

1.  $\{\Delta^d y_t\}$  が共分散定常なら  $\{y_t\}$  を  $d$  次の和分 (単位根) 過程という.  $\{\Delta y_t\}$  が WN なら  $\{y_t\}$  をランダム・ウォークという.  $(p, d, q)$  次の自己回帰和分移動平均 (ARIMA) 過程は, 任意の  $t$  について  $\phi(L)(\Delta^d y_t - \mu) = \theta(L)w_t$ . ただし  $\phi(L), \theta(L)$  はラグ多項式で  $\{w_t\}$  は WN.
2. AR モデルの係数の OLS 推定量は不偏でないが一致性をもつ.
3. ARMA モデルの尤度関数は予測誤差分解で計算する. 時系列の同時 pdf を尤度とする ML 法を厳密な ML 法, 初期値を所与とした条件つき pdf を尤度とする ML 法を条件つき ML 法という.
4. ARMA モデルの次数は AIC・SBIC・HQIC 等のモデル選択基準で選ぶ.

## 目次

1	ARIMA 過程	1
1.1	差分と和分 . . . . .	1
1.2	和分 (単位根) 過程 (p. 128) . . . . .	2
1.3	ARIMA 過程 (p. 138) . . . . .	2
2	AR モデルの OLS 推定	2
2.1	OLS 推定量 . . . . .	2
2.2	有限標本特性 . . . . .	2
2.3	漸近特性 . . . . .	2

3	正規 ARMA モデルの ML 推定	3
3.1	最尤 (ML) 法 . . . . .	3
3.2	予測誤差分解 . . . . .	3
3.3	厳密な ML 法 (p. 137) . . . . .	4
3.4	条件つき ML 法 . . . . .	4
4	次数選択	4
4.1	仮説検定とモデル選択 . . . . .	4
4.2	Kullback–Leibler 情報量 . . . . .	4
4.3	モデル選択基準 (p. 132) . . . . .	4
5	今日のキーワード	5
6	次回までの準備	5

## 1 ARIMA 過程

### 1.1 差分と和分

$\{x_t\}$  を  $t = 1$  から始まる数列とする.

定義 1.  $\{x_t\}$  の差分 (階差) は  $\{\Delta x_t\}$ .

定義 2.  $\{x_t\}$  の和分は  $t \geq 1$  について

$$S_t := x_1 + \cdots + x_t$$

注 1.  $t \geq 1$  について

$$\begin{aligned} \Delta S_t &:= S_t - S_{t-1} \\ &= x_1 + \cdots + x_t - (x_1 + \cdots + x_{t-1}) \\ &= x_t \end{aligned}$$

すなわち和分は差分の逆の演算. 離散空間上の差分と和分の関係は, 連続空間上の微分と積分の関係に相当.

## 1.2 和分（単位根）過程（p. 128）

$\{y_t\}$  を確率過程とする。

定義 3.  $\{\Delta^d y_t\}$  が共分散定常なら  $\{y_t\}$  を  $d$  次の和分（単位根）過程という。

注 2.  $I(d)$  と書く。  $I(0)$  = 共分散定常。

注 3.  $I(d)$  は  $I(0)$  に変換して分析する。

定義 4.  $\{\Delta y_t\}$  がホワイト・ノイズなら  $\{y_t\}$  をランダム・ウォークという。

注 4.  $\{w_t\}$  を WN とすると、任意の  $t$  について

$$\Delta y_t = w_t$$

AR(1) は、任意の  $t$  について

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

ただし  $\phi(L) := 1 - \phi L$ . ランダム・ウォークは  $\mu := 0$ ,  $\phi(L) := \Delta = 1 - L$  の AR(1). このとき  $\phi(z) := 1 - z = 0$  の根は  $z = 1$  (単位根).

## 1.3 ARIMA 過程（p. 138）

$\{y_t\}$  を  $I(d)$  とする。

定義 5.  $(p, d, q)$  次の自己回帰和分移動平均 (autoregressive integrated moving average, ARIMA) 過程は、任意の  $t$  について

$$\begin{aligned} \phi(L)(\Delta^d y_t - \mu) &= \theta(L)w_t \\ \{w_t\} &\sim \text{WN}(\sigma^2) \end{aligned}$$

ただし  $\phi(L) := 1 - \phi_1 L - \dots - \phi_p L^p$ ,  $\theta(L) := 1 - \theta_1 L - \dots - \theta_q L^q$ .

注 5. ARIMA( $p, d, q$ ) と書く。

## 2 AR モデルの OLS 推定

### 2.1 OLS 推定量

時系列  $(y_0, \dots, y_T)$  に平均 0 の AR(1) モデルを仮定する。すなわち  $t = 1, \dots, T$  について

$$\begin{aligned} y_t &= \phi y_{t-1} + w_t \\ \{w_t\} &\sim \text{WN}(\sigma^2) \end{aligned}$$

ただし  $|\phi| < 1$ .  $\phi$  の OLS 推定量を  $\hat{\phi}_T$  とすると

$$\hat{\phi}_T = \frac{\sum_{t=1}^T y_{t-1} y_t}{\sum_{t=1}^T y_{t-1}^2}$$

### 2.2 有限標本特性

定理 1. 一般に

$$E(\hat{\phi}_T) \neq \phi$$

証明. 式変形すると

$$\begin{aligned} \hat{\phi}_T &= \frac{\sum_{t=1}^T y_{t-1} y_t}{\sum_{t=1}^T y_{t-1}^2} \\ &= \frac{\sum_{t=1}^T y_{t-1}(\phi y_{t-1} + w_t)}{\sum_{t=1}^T y_{t-1}^2} \\ &= \phi + \frac{\sum_{t=1}^T y_{t-1} w_t}{\sum_{t=1}^T y_{t-1}^2} \end{aligned}$$

第 2 項の期待値は

$$\begin{aligned} &E\left(\frac{\sum_{t=1}^T y_{t-1} w_t}{\sum_{t=1}^T y_{t-1}^2}\right) \\ &= \sum_{t=1}^T E\left(\frac{y_{t-1} w_t}{\sum_{t=1}^T y_{t-1}^2}\right) \\ &= E\left(\frac{y_0 w_1}{\sum_{t=1}^T y_{t-1}^2}\right) + \dots + E\left(\frac{y_{T-1} w_T}{\sum_{t=1}^T y_{t-1}^2}\right) \\ &= \text{cov}\left(\frac{y_0}{\sum_{t=1}^T y_{t-1}^2}, w_1\right) + \dots \\ &\quad + \text{cov}\left(\frac{y_{T-1}}{\sum_{t=1}^T y_{t-1}^2}, w_T\right) \end{aligned}$$

$w_1$  は  $y_1, \dots, y_{T-1}$  と相関するので第 1 項は一般に 0 でない。同様に他の項も一般に 0 でない。□

注 6. 無作為標本でないため OLS 推定量は不偏でない。

### 2.3 漸近特性

定理 2.

$$\text{plim}_{T \rightarrow \infty} \hat{\phi}_T = \phi$$

証明. 式変形すると

$$\begin{aligned} \hat{\phi}_T &= \phi + \frac{\sum_{t=1}^T y_{t-1} w_t}{\sum_{t=1}^T y_{t-1}^2} \\ &= \phi + \frac{(1/T) \sum_{t=1}^T y_{t-1} w_t}{(1/T) \sum_{t=1}^T y_{t-1}^2} \end{aligned}$$

エルゴード定理より

$$\begin{aligned}\text{plim}_{T \rightarrow \infty} \frac{1}{T} \sum_{t=1}^T y_{t-1} w_t &= E(y_{t-1} w_t) \\ \text{plim}_{T \rightarrow \infty} \frac{1}{T} \sum_{t=1}^T y_{t-1}^2 &= E(y_{t-1}^2)\end{aligned}$$

漸近演算より

$$\begin{aligned}\text{plim}_{T \rightarrow \infty} \hat{\phi}_T &= \phi + \frac{\text{plim}_{T \rightarrow \infty} (1/T) \sum_{t=1}^T y_{t-1} w_t}{\text{plim}_{T \rightarrow \infty} (1/T) \sum_{t=1}^T y_{t-1}^2} \\ &= \phi + \frac{E(y_{t-1} w_t)}{E(y_{t-1}^2)}\end{aligned}$$

$E(y_{t-1} w_t) = \text{cov}(y_{t-1}, w_t) = 0$  より第 2 項は 0.

□

注 7. すなわち OLS 推定量は一致性をもつ。また漸近正規性も証明できる (省略)。

### 3 正規 ARMA モデルの ML 推定

#### 3.1 最尤 (ML) 法

パラメトリックな確率過程を仮定する。母数を  $\theta$  とし、観測する時系列の同時 pmf・pdf を  $f(\cdot; \theta)$  とする。

**定義 6.** ある母数の下で標本の実現値を観測する確率 (密度) を、その母数の尤度という。

注 8.  $(y_1, \dots, y_T)$  を観測する確率 (密度) は

$$f(y_1, \dots, y_T; \theta)$$

これを  $\theta$  の「尤もらしさ」と解釈する。

**定義 7.** 標本の pmf・pdf を母数の尤度を表す関数とみたものを尤度関数という。

注 9.  $L(\theta; y_1, \dots, y_T)$  と書く ( $(y_1, \dots, y_T)$  と  $\theta$  の位置が pmf・pdf と逆)。

注 10.  $(y_1, \dots, y_T)$  を観測したときの  $\theta$  の尤度関数は

$$L(\theta; y_1, \dots, y_T) := f(y_1, \dots, y_T; \theta)$$

**定義 8.** 尤度関数の対数を対数尤度関数という。

注 11.  $\ell(\theta; y_1, \dots, y_T)$  と書く。

注 12.  $(y_1, \dots, y_T)$  を観測したときの  $\theta$  の対数尤度関数は

$$\begin{aligned}\ell(\theta; y_1, \dots, y_T) &:= \ln L(\theta; y_1, \dots, y_T) \\ &= \ln f(y_1, \dots, y_T; \theta)\end{aligned}$$

**定義 9.** (対数) 尤度関数を最大にする解を母数の推定値とする手法を最尤 (*maximum likelihood*, *ML*) 法という。

**定義 10.** ML 法による推定量を *ML 推定量* という。

**定理 3.** *ML 推定量* は一般に漸近有効。

証明. 省略 (大学院レベル).

□

#### 3.2 予測誤差分解

時系列  $(y_1, \dots, y_T)$  の同時 pdf を  $f(\cdot)$ 、条件つき pdf を  $f(\cdot|\cdot)$  で表す。

**定理 4** (予測誤差分解). 任意の  $(y_1, \dots, y_T)$  について

$$\begin{aligned}f(y_1, \dots, y_T) \\ = f(y_T|y_{T-1}, \dots, y_1) \cdots f(y_2|y_1)f(y_1)\end{aligned}$$

証明. 条件つき pdf の定義より、任意の  $(y_1, \dots, y_T)$  について

$$\begin{aligned}f(y_1, \dots, y_T) \\ = \frac{f(y_1, \dots, y_T)}{f(y_1, \dots, y_{T-1})} \frac{f(y_1, \dots, y_{T-1})}{f(y_1, \dots, y_{T-2})} \cdots \\ \frac{f(y_1, y_2)}{f(y_1)} f(y_1) \\ = f(y_T|y_{T-1}, \dots, y_1) f(y_{T-1}|y_{T-2}, \dots, y_1) \cdots \\ f(y_2|y_1) f(y_1)\end{aligned}$$

□

**例 1.** 時系列  $(y_1, \dots, y_T)$  に平均 0 の正規 AR(1) モデルを仮定する。すなわち  $t = 1, \dots, T$  について

$$\begin{aligned}y_t &= \phi y_{t-1} + w_t \\ \{w_t\} &\sim \text{IN}(0, \sigma^2)\end{aligned}$$

ただし  $|\phi| < 1$ .  $\text{var}(y_1) = \sigma^2 / (1 - \phi^2)$  より

$$y_1 \sim N\left(0, \frac{\sigma^2}{1 - \phi^2}\right)$$

また  $t = 2, \dots, T$  について

$$y_t | y_{t-1}, \dots, y_1 \sim N(\phi y_{t-1}, \sigma^2)$$

予測誤差分解より尤度関数は

$$\begin{aligned} L(\phi, \sigma^2; y_1, \dots, y_T) &:= f(y_1, \dots, y_T) \\ &= f(y_T | y_{T-1}, \dots, y_1) \cdots f(y_2 | y_1) f(y_1) \\ &= \prod_{t=2}^T \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{(y_t - \phi y_{t-1})^2}{2\sigma^2}\right) \\ &\quad \frac{1}{\sqrt{2\pi\sigma^2/(1-\phi^2)}} \exp\left(-\frac{y_1^2}{2\sigma^2/(1-\phi^2)}\right) \end{aligned}$$

対数尤度関数は

$$\begin{aligned} \ell(\phi, \sigma^2; y_1, \dots, y_T) &:= \ln L(\phi, \sigma^2; y_1, \dots, y_T) \\ &= \sum_{t=2}^T \left\{ -\frac{1}{2} \ln 2\pi - \frac{1}{2} \ln \sigma^2 - \frac{(y_t - \phi y_{t-1})^2}{2\sigma^2} \right\} \\ &\quad - \frac{1}{2} \ln 2\pi - \frac{1}{2} \ln \frac{\sigma^2}{1-\phi^2} - \frac{y_1^2}{2\sigma^2/(1-\phi^2)} \\ &= -\frac{T}{2} \ln 2\pi - \frac{T}{2} \ln \sigma^2 + \frac{1}{2} \ln(1-\phi^2) \\ &\quad - \frac{(1-\phi^2)y_1^2}{2\sigma^2} - \frac{1}{2\sigma^2} \sum_{t=2}^T (y_t - \phi y_{t-1})^2 \end{aligned}$$

### 3.3 厳密な ML 法 (p. 137)

定義 11.  $(y_1, \dots, y_T)$  の同時 pdf を尤度とする ML 法を厳密な ML 法という。

注 13. 漸近有効だが尤度の計算が複雑 (ARMA モデルを状態空間モデルで表現し, カルマン・フィルタで尤度を計算する)。

### 3.4 条件つき ML 法

定義 12. 初期値  $(y_1, \dots, y_p)$  と  $(w_{p-q+1}, \dots, w_p)$  を所与とした  $(y_{p+1}, \dots, y_T)$  の条件つき pdf を尤度とする ML 法を条件つき ML 法という。

注 14. 初期値の周辺 pdf を省くと漸近有効でないが推定が簡単になる。AR モデルなら条件つき ML 法 = OLS。

## 4 次数選択

### 4.1 仮説検定とモデル選択

予測モデルの次数選択は仮説検定と異なる。

1. 真の次数が無限大なら真のモデルは推定できず仮説検定も無意味。
2. 真の次数が有限でも推定する係数が多いと予測値が不安定になる。

モデル選択基準による次数選択が便利。

### 4.2 Kullback-Leibler 情報量

確率変数  $Y$  の真の分布を  $f_0(\cdot)$ , 予測モデルの下での分布を  $f(\cdot)$  とする。

定義 13.  $f(\cdot)$  の  $f_0(\cdot)$  に対する Kullback-Leibler 情報量は

$$I(f(\cdot); f_0(\cdot)) := -E_{f_0} \left( \ln \frac{f(Y)}{f_0(Y)} \right)$$

注 15.  $f(\cdot)$  の  $f_0(\cdot)$  に対する「距離」を表す。  $f(\cdot) = f_0(\cdot)$  なら「距離」は 0 で最小。ただし真の次数が無限大なら  $f_0(\cdot)$  は予測に使えない。式変形すると

$$I(f(\cdot); f_0(\cdot)) = -E_{f_0}(\ln f(Y)) + E_{f_0}(\ln f_0(Y))$$

第 1 項を最小化, すなわち  $E_{f_0}(\ln f(Y))$  を最大化する  $f(\cdot)$  が最適な予測モデル。  $E_{f_0}(\ln f(Y))$  は未知なので推定が必要。

### 4.3 モデル選択基準 (p. 132)

定常過程  $\{Y_t\}$  の 1 期先予測モデルを  $f(\cdot; \theta)$  とする。  $E(\ln f(Y_t; \theta))$  を最大化する  $\theta$  を  $\theta^*$  とする。  $E(\ln f(Y_t; \theta^*))$  の推定は 2 つの推定を含む。

1.  $\theta^*$  の推定
2.  $\theta^*$  を所与とした  $E(\ln f(Y_t; \theta^*))$  の推定

$\theta^*$  が既知ならエルゴード定理より

$$\text{plim}_{T \rightarrow \infty} \frac{1}{T} \sum_{t=1}^T \ln f(Y_t; \theta^*) = E(\ln f(Y_t; \theta^*))$$

$\theta^*$  の ML 推定量を  $\hat{\theta}_T$  とする。  $\theta^*$  を  $\hat{\theta}_T$  で置き換えると偏りが生じるので修正が必要。未知係数の数を  $k$  とする。

補題 1. 任意の  $\theta$  と  $(y_1, \dots, y_T)$  について

$$\sum_{t=1}^T \ln f(y_t; \theta) = \ell(\theta; y_1, \dots, y_T)$$

証明. 予測誤差分解より

$$f(y_1, \dots, y_T; \theta) = \prod_{t=1}^T f(y_t; \theta)$$

したがって

$$\begin{aligned} \ell(\theta; y_1, \dots, y_T) &:= \ln f(y_1, \dots, y_T; \theta) \\ &= \sum_{t=1}^T \ln f(y_t; \theta) \end{aligned}$$

□

定義 14. 赤池の情報量基準 (*Akaike's information criterion, AIC*) は

$$\text{AIC} := -2\ell(\hat{\theta}_T; y_1, \dots, y_T) + 2k$$

注 16. AIC が最小のモデルを選択する. 第 2 項は偏りの修正項であり, モデルの大きさに対するペナルティーと解釈できる.

定義 15. 真のモデルを選ぶ確率が  $T \rightarrow \infty$  で 1 に収束する性質をモデル選択基準の一致性という.

注 17. AIC は一致性をもたない (過剰定式化の傾向がある).

定義 16. Schwarz のベイズ情報量基準 (*Schwarz's Bayesian information criterion, SBIC*) は

$$\text{SBIC} := -2\ell(\hat{\theta}_T; y_1, \dots, y_T) + k \ln T$$

注 18.  $\theta^*$  をベイズ法で推定した場合の周辺尤度  $E(\ell(\theta^*; y_1, \dots, y_T))$  の近似から得られる.

注 19. SBIC は一致性をもつ.  $\ln T > 2$  ならモデルの大きさに対するペナルティーが AIC より大きく, AIC より小さいモデルを選択する.

定義 17. Hannan-Quinn の基準 (*Hannan-Quinn criterion, HQC*) は

$$\text{HQC} := -2\ell(\hat{\theta}_T; y_1, \dots, y_T) + 2k \ln \ln T$$

注 20. HQC も一致性をもつ. モデルの大きさに対するペナルティーは AIC と SBIC の中間.

## 5 今日のキーワード

差分 (階差), 和分, 和分 (単位根) 過程, ランダム・ウォーク, 自己回帰和分移動平均 (ARIMA) 過程, 尤度, 尤度関数, 対数尤度関数, 最尤 (ML) 法, ML 推定量, 予測誤差分解, 厳密な ML 法, 条件つき ML 法, Kullback-Leibler 情報量, 赤池の情報量基準 (AIC), 一致性, Schwarz のベイズ情報量基準 (SBIC), Hannan-Quinn の基準 (HQC)

## 6 次回までの準備

提出 宿題 5

復習 教科書第 7 章 1.3, 2.2-2.3 節

予習 教科書第 7 章 7.4.1 節