

第5回 1変量時系列モデルの定式化と推定 (7.3.2, 7.5.1)

村澤 康友

2023年10月23日

今日のポイント

- $\{\Delta^d y_t\}$ 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. $\{\Delta^d y_t\}$ が $\text{ARMA}(p, q)$ なら $\{y_t\}$ を (p, d, q) 次の自己回帰和分移動平均 (ARIMA) 過程という.
- 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.
- 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.
- ARMA モデルの次数は AIC・SBIC・HQc 等のモデル選択基準で選ぶ.

3.2	予測誤差分解	3
3.3	厳密な ML 法 (p. 221)	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. 224)	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. 231)

$\{y_t\}$ 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.

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. 231)	1
1.3	ARIMA 過程 (p. 221)	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

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 $\phi = 1$ 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. 221)

$\{y_t\}$ を $I(d)$ とする.

定義 5. $\{\Delta^d y_t\}$ が ARMA(p, q) なら $\{y_t\}$ を (p, d, q) 次の自己回帰和分移動平均 (ARIMA) 過程という.

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

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

ただし $|\phi| < 1$. ϕ 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. \square

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 θ 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 θ 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 θ の位置が pmf・pdf と逆)。

注 10. (y_1, \dots, y_T) を観測したときの θ 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 θ 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

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

□

注 13. 確率の乗法定理と同じ。

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 $|\phi| < 1$. *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

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

*1 $\text{IN}(0, \sigma^2)$ は独立な $N(0, \sigma^2)$ の意味。

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. 221)

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 14. 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 15. 初期値の周辺 pdf を省くため漸近有効でないが, 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 16. $f(\cdot)$ 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. 224)

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 θ を θ^* とする。 $E(\ln f(Y_t; \theta^*))$ の推定は 2 つの推定を含む。

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

θ^* が既知ならエルゴード定理より

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

θ^* の ML 推定量を $\hat{\theta}_T$ とする。左辺の θ^* を $\hat{\theta}_T$ で置き換えると右辺の推定量として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 θ 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 17. 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**一貫性**という.

注 18. AIC は一貫性をもたない (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 19. θ^* をベイズ法で推定した場合の周辺尤度 $E(\ell(\theta^*; y_1, \dots, y_T))$ のラプラス近似から得られる.

注 20. SBIC は一貫性をもつ. $\ln T > 2$ 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 21. HQC も一貫性をもつ. 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), 一貫性, 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 3.2, 5.1 節, 復習テスト 5

予習 特になし