

第 3 章「ARMA モデルに基づく予測」

1 . 最良線形不偏予測量 (BLUP: Best Linear Unbiased Predictor)

$\{y_t\}$ を $E(y_t) = \mu$ の定常過程として, $y(T) = (y_1, \dots, y_T)'$ に基づく y_{T+1} の任意の予測量を $\tilde{y}_{T+1} = f(y(T))$ とする .

定義: $E(y_{T+1} - \tilde{y}_{T+1}) = 0$ (予測誤差の期待値が 0) のとき, \tilde{y}_{T+1} は y_{T+1} の不偏予測量であるという . 不偏予測量の中で, 予測の平均 2 乗誤差 $MSE(\tilde{y}_{T+1}) = E(y_{T+1} - \tilde{y}_{T+1})^2$ を最小にする予測量を最良不偏予測量 (BUP: Best Unbiased Predictor) という .

Note: 予測量が不偏ならば, 予測の MSE は予測誤差の分散と一致する .

定理 1 BUP は条件付き期待値 $E(y_{T+1}|y(T))$ である .

[証明]

$$\begin{aligned} MSE(\tilde{y}_{T+1}) &= E \left[(y_{T+1} - \tilde{y}_{T+1})^2 \right] \\ &= E \left[\{y_{T+1} - E(y_{T+1}|y(T)) - (\tilde{y}_{T+1} - E(y_{T+1}|y(T)))\}^2 \right] \\ &= E \left[\{y_{T+1} - E(y_{T+1}|y(T))\}^2 \right] + E \left[\{\tilde{y}_{T+1} - E(y_{T+1}|y(T))\}^2 \right] \end{aligned}$$

を得るから, これを最小にする \tilde{y}_{T+1} は, 明らかに $E(y_{T+1}|y(T))$ である .

例 1 : $\{y_t\}$ が平均 μ の正規定常過程であるとき, y_{T+1} の BUP は

$$E(y_{T+1}|y(T)) = \mu + \Sigma_{12}\Sigma_{22}^{-1}(y(T) - \mu e) \tag{1}$$

であり, 予測の MSE は

$$\begin{aligned} E \left[\{y_{T+1} - E(y_{T+1}|y(T))\}^2 \right] &= E \left[\left\{ y_{T+1} - \mu - \Sigma_{12}\Sigma_{22}^{-1}(y(T) - \mu e) \right\}^2 \right] \\ &= \Sigma_{11} - \Sigma_{12}\Sigma_{22}^{-1}\Sigma_{21} \end{aligned}$$

ただし, $e = (1, \dots, 1)': T \times 1$ であり, さらに,

$$\Sigma_{11} = V(y_{T+1}) = \gamma_0, \quad \Sigma_{21} = Cov(y(T), y_{T+1}) = \Sigma'_{12}, \quad \Sigma_{22} = V(y(T)) : T \times T.$$

Note: 無相関過程ならば, $E(y_{T+1}|y(T)) = E(y_{T+1}) = \mu$

定義: y_{T+1} の線形予測量 $a_0 + a_1 y_T + a_2 y_{T-1} + \dots + a_T y_1$ の中で, 予測の MSE を最小にする予測量を最良線形不偏予測量 (BLUP) といい, \hat{y}_{T+1} で表す .

定理 2 BLUP を与える a_0 と $a = (a_1, \dots, a_T)'$ は

$$a_0 = \mu \left(1 - \sum_{t=1}^T a_t \right), \quad a = \Gamma_T^{-1} \gamma(T) \tag{2}$$

である．ここで，

$$\Gamma_T = [((Cov(y_s, y_t)))] = [((\gamma_{s-t}))] : T \times T, \quad \gamma(T) = (\gamma_1, \dots, \gamma_T)'$$

[証明]

$$f(a_0, a) = E(y_{T+1} - a_0 - a_1 y_T - a_2 y_{T-1} - \dots - a_T y_1)^2$$

を a_0 と a で偏微分して 0 とおく (正規方程式) ことにより，解を得る．なお，予測量の不偏性は， a_0 による偏微分

$$E \left[y_{T+1} - a_0 - \sum_{t=1}^T a_t y_{T+1-t} \right] = E[y_{T+1} - \hat{y}_{T+1}] = 0$$

から必然的に成り立つ (回帰モデルの LSE が不偏であることと同様) ．

BLUP \hat{y}_{T+1} の性質

- (a) $\hat{y}_{T+1} = \mu + \sum_{t=1}^T a_t (y_{T+1-t} - \mu)$, $a = \Gamma_T^{-1} \gamma(T)$
- (b) $V(y_{T+1} - \hat{y}_{T+1}) = \gamma_0 - \gamma(T)' \Gamma_T^{-1} \gamma(T)$
- (c) 正規定常過程では BUP となる．
- (d) $E[(y_{T+1} - \hat{y}_{T+1}) y_t] = 0$ ($t = 1, \dots, T$)
- (e) BLUP は y_{T+1} を $1, y_T, \dots, y_1$ で張られるベクトル空間に射影したものである (性質 $E[(y_{T+1} - \hat{y}_{T+1}) \times 1] = 0$ および (d) による) ．

上の性質 (e) より， $\Pi(x|y)$ を射影演算子 (Projection Operator) とするとき，次のことが成り立つ．

$$\hat{y}_{T+1} = \Pi(y_{T+1}|1, y_T, \dots, y_1) \tag{3}$$

射影演算子の性質

Q, R を確率変数 (分散有限) ， W を $T \times 1$ の確率ベクトル (共分散行列 Γ) ， $\alpha_1, \dots, \alpha_T, \beta$ を定数とする．

1. $\Pi(Q|W) = E(Q) + a'(W - E(W))$ ，ただし $\Gamma a = Cov(W, Q)$
2. $E[(Q - \Pi(Q|W))^2] = V(Q) - a' Cov(W, Q)$
3. $\Pi(\alpha_1 Q + \alpha_2 R + \beta|W) = \alpha_1 \Pi(Q|W) + \alpha_2 \Pi(R|W) + \beta$
4. $\Pi(\sum_{t=1}^T \alpha_t W_t + \beta|W) = \sum_{t=1}^T \alpha_t W_t + \beta$
5. $Cov(W, Q) = 0$ ならば $\Pi(Q|W) = E(Q)$

例2： AR(p) モデル $y_t = m + \phi_1 y_{t-1} + \cdots + \phi_p y_{t-p} + \varepsilon_t$ では，(2) 式より， $T > p$ ならば

$$a = \Gamma_T^{-1} \gamma(T) = \begin{pmatrix} \phi_1 \\ \phi_2 \\ \vdots \\ \phi_p \\ 0 \\ \vdots \\ 0 \end{pmatrix}, \quad a_0 = \mu(1 - \sum_{t=1}^T a_t) = \mu(1 - \sum_{j=1}^p \phi_j) = m$$

を得る．他方，射影演算子を使うことにより，

$$\begin{aligned} \hat{y}_{T+1} &= \Pi(y_{T+1}|1, y_T, \cdots, y_1) \\ &= \Pi(m + \phi_1 y_T + \phi_2 y_{T-1} + \cdots + \phi_p y_{T+1-p} + \varepsilon_t | 1, y_T, \cdots, y_1) \\ &= m + \phi_1 y_T + \phi_2 y_{T-1} + \cdots + \phi_p y_{T+1-p} \end{aligned}$$

このとき，

$$MSE(\hat{y}_{T+1}) = \gamma_0 - \gamma(T)' \Gamma_T^{-1} \gamma(T) = V(\varepsilon_{T+1}) = \sigma^2$$

例3： MA(1) モデル $y_t = m + \varepsilon_t - \theta_1 \varepsilon_{t-1}$ では，(2) を使って

$$\begin{aligned} \hat{y}_2 &= a_0 + a_1 y_1 \\ &= m(1 - a_1) + \frac{\gamma_1}{\gamma_0} y_1 = m(1 - \rho_1) + \rho_1 y_1 \\ &= m \left(1 - \frac{-\theta_1}{1 + \theta_1^2} \right) + \frac{-\theta_1}{1 + \theta_1^2} y_1 \\ &= m - \frac{\theta_1}{1 + \theta_1^2} (y_1 - m) \end{aligned}$$

$$MSE(\hat{y}_2) = \gamma_0 - \frac{\gamma_1^2}{\gamma_0} = \frac{1 + \theta_1^2 + \theta_1^4}{1 + \theta_1^2} \sigma^2 \quad (4)$$

注： MA モデルに関する予測は，推定の場合も同様であるが，AR モデルの場合よりも複雑である．予測の場合には，議論を簡単にするために，あたかも無限の過去からの観測値があるとして， $\hat{y}_{T+1} = \Pi(y_{T+1}|1, y_T, \cdots, y_1, \cdots)$ を考えることが多い．このとき，次の事実が成立する．

$$\Pi(\varepsilon_t | 1, y_T, \cdots, y_1, \cdots) = \begin{cases} 0 & (t > T) \\ \varepsilon_t & (t \leq T) \end{cases}$$

したがって，

$$\begin{aligned} \Pi(y_2 | 1, y_1, y_0, \cdots) &= \Pi(m + \varepsilon_2 - \theta_1 \varepsilon_1 | 1, y_1, \cdots) \\ &= m - \theta_1 \varepsilon_1 \end{aligned}$$

を得る．このとき，予測誤差分散は

$$MSE(\Pi(y_2 | 1, y_1, y_0, \cdots)) = V(\varepsilon_2) = \sigma^2$$

となり，上の (4) よりも小さくなる．

2 . h 期先の予測 (h -step ahead prediction)

定理3 $y(T) = (y_1, \dots, y_T)'$ に基づく h 時点先の値 y_{T+h} の BLUP は

$$\hat{y}_{T+h} = \Pi(y_{T+h}|1, y_T, \dots, y_1)$$

で与えられる．

例4 : AR(1) モデル $y_t = m + \phi_1 y_{t-1} + \varepsilon_t$ の場合

$$\begin{aligned} y_{T+h} &= m + \phi_1 y_{T+h-1} + \varepsilon_{T+h} \\ &= m + \phi_1(m + \phi_1 y_{T+h-2} + \varepsilon_{T+h-1}) + \varepsilon_{T+h} \\ &= m(1 + \phi_1 + \dots + \phi_1^{h-1}) + \phi_1^h y_T + \varepsilon_{T+h} + \phi_1 \varepsilon_{T+h-1} + \dots + \phi_1^{h-1} \varepsilon_{T+1} \end{aligned}$$

であるから，

$$\begin{aligned} \hat{y}_{T+h} &= m(1 + \phi_1 + \dots + \phi_1^{h-1}) + \phi_1^h y_T \\ MSE(\hat{y}_{T+h}) &= V(\varepsilon_{T+h} + \phi_1 \varepsilon_{T+h-1} + \dots + \phi_1^{h-1} \varepsilon_{T+1}) \\ &= \sigma^2(1 + \phi_1^2 + \phi_1^4 + \dots + \phi_1^{2(h-1)}) \\ &\rightarrow \sigma^2 \frac{1}{1 - \phi_1^2} = \gamma_0 \quad (h \rightarrow \infty) \end{aligned}$$

例5 : MA(1) モデル $y_t = m + \varepsilon_t - \theta_1 \varepsilon_{t-1}$ では， $h \geq 2$ ならば，明らかに

$$\begin{aligned} \hat{y}_{T+h} &= \Pi(m + \varepsilon_{T+h} - \theta_1 \varepsilon_{T+h-1}|1, y_T, \dots, y_1) \\ &= m \quad (h \geq 2) \\ MSE(\hat{y}_{T+h}) &= V(\varepsilon_{T+h} - \theta_1 \varepsilon_{T+h-1}) \\ &= \sigma^2(1 + \theta_1^2) = \gamma_0 \quad (h \geq 2) \end{aligned}$$

3 . 射影の応用 (Application of projection)

再帰的射影 (Recursive projection)

まず， y を $1, x_1, x_2$ に射影する (= $1, x_1, x_2$ に基づいて y を予測する) ことにより，次の表現が得られる．

$$y = \Pi(y|1, x_1, x_2) + \varepsilon = a_0 + a_1 x_1 + a_2 x_2 + \varepsilon \quad (5)$$

ここで，

$$E(\varepsilon) = 0, \quad E(x_1 \varepsilon) = 0, \quad E(x_2 \varepsilon) = 0$$

次に，(5) の両辺を 1 と x_1 に射影して，

$$\Pi(y|1, x_1) = a_0 + a_1 x_1 + a_2 \Pi(x_2|1, x_1) \quad (6)$$

を得る . (5) から (6) を差し引いて ,

$$y - \Pi(y|1, x_1) = a_2 (x_2 - \Pi(x_2|1, x_1)) + \varepsilon$$

右辺第 1 項と第 2 項は直交するから ,

$$\Pi(y - \Pi(y|1, x_1)|x_2 - \Pi(x_2|1, x_1)) = a_2 (x_2 - \Pi(x_2|1, x_1))$$

となり , したがって

$$y = \Pi(y|1, x_1) + \Pi(y - \Pi(y|1, x_1)|x_2 - \Pi(x_2|1, x_1)) + \varepsilon \quad (7)$$

を得る . (5) と (7) から ,

$$\Pi(y|1, x_1, x_2) = \Pi(y|1, x_1) + \Pi(y - \Pi(y|1, x_1)|x_2 - \Pi(x_2|1, x_1))$$

一般に , 次の recursive projection に関する定理が成り立つ .

定理 4 Ω を確率変数の集合とするとき ,

$$\Pi(y|\Omega, x) = \Pi(y|\Omega) + \Pi(y - \Pi(y|\Omega)|x - \Pi(x|\Omega)) \quad (8)$$

定理 4 から , 次の繰り返し射影の法則 (Law of iterated projections) が得られる

定理 5

$$\Pi(\Pi(y|\Omega, x)|\Omega) = \Pi(y|\Omega)$$

[証明] (8) は

$$\Pi(y|\Omega, x) = \Pi(y|\Omega) + a(x - \Pi(x|\Omega))$$

と表すことができるから , この両辺を Ω に射影することにより結果を得る . ここで , 次の事実を使った .

$$\Pi(x - \Pi(x|\Omega)|\Omega) = 0, \quad \Pi(\Pi(y|\Omega)|\Omega) = \Pi(y|\Omega)$$

射影の考え方を使って , 偏自己相関に関して次のことが成り立つ .

定理 6 定常過程 $\{y_t\}$ における時差 h の自己相関は , 2 つの予測誤差 $y_t - \Pi(y_t|y_{t+1}, \dots, y_{t+h-1})$ と $y_{t+h} - \Pi(y_{t+h}|y_{t+1}, \dots, y_{t+h-1})$ の自己相関係数に等しい .

[証明の方針] 時差 h の偏自己相関を ϕ_{hh} とするとき , 次のことを証明すればよい .

$$\phi_{hh} = \frac{Cov(\tilde{y}_t, \tilde{y}_{t+h})}{\sqrt{V(\tilde{y}_t)V(\tilde{y}_{t+h})}}$$

ここで ,

$$\begin{aligned} \tilde{y}_t &= y_t - \Pi(y_t|y_{t+1}, \dots, y_{t+h-1}) \\ \tilde{y}_{t+h} &= y_{t+h} - \Pi(y_{t+h}|y_{t+1}, \dots, y_{t+h-1}) \end{aligned}$$