

# 第 4 章「ARMA モデルの推定」

## 1. Box-Jenkins によるモデル・ビルディングの方法

(1) Identification (同定, 特定化)

⇒ (2) Estimation (推定)

⇒ (3) Diagnostic Checking (診断)

(1) Identification: ARMA(p,q) モデルの次数 p, q を決める. 標本自己相関, 標本偏自己相関, 標本逆自己相関などを手がかりとする.

(2) Estimation: ARMA(p,q) モデルのパラメータの推定

$$\phi(L)y_t = m + \theta(L)\varepsilon_t$$

におけるパラメータ:

$$\phi = (\phi_1, \dots, \phi_p)'$$

$$\theta = (\theta_1, \dots, \theta_q)'$$

$$m = \text{定数項}$$

$$\sigma^2 = \text{誤差項 } \varepsilon_t \text{ の分散}$$

推定量

・非線形最小 2 乗推定量 (NLSE)

$$\sum \varepsilon_t^2 = \sum \left\{ \frac{\phi(L)y_t - m}{\theta(L)} \right\}^2 \text{ を最小にする}$$

Note. モデルが AR(p) の場合は, 通常の最小 2 乗法となる.  $\sigma^2$  は残差から推定.

・最尤推定量 (MLE)

誤差項に正規分布を仮定して, 次の対数尤度関数 (密度関数の対数) を最大化する.

$$\text{対数尤度} = -\frac{T}{2} \log(2\pi\sigma^2) - \frac{1}{2} \log |\Sigma| - \frac{1}{2\sigma^2} (y - \mu)' \Sigma^{-1} (y - \mu)$$

これらの推定量は次の性質をもつ.

定理 1 定常, 反転可能な ARMA モデルにおいては, パラメータ  $\phi, \theta, m$  の NLSE および MLE は, 漸近的に (標本サイズ  $T$  が大きくなるにつれて) 正規分布に従い,

$$\sqrt{T}(\text{推定量のベクトル} - \text{真の値のベクトル}) \Rightarrow N(0, W^{-1})$$

ここで,  $W$  は Fisher の情報行列であり,

$$W = \lim_{T \rightarrow \infty} E \left[ -\frac{1}{T} \frac{\partial^2}{\partial \beta \partial \beta'} \left\{ -\frac{1}{2\sigma^2} \sum_{t=1}^T \varepsilon_t^2 \right\} \right], \quad \beta = (\phi', \theta', m)'$$

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

$$\sqrt{T}(\hat{\beta} - \beta) \Rightarrow N(0, W^{-1}), \quad \beta = (\phi_1, m)'$$

$$\begin{aligned} W &= \lim_{T \rightarrow \infty} E \left[ -\frac{1}{T} \frac{\partial^2}{\partial \beta \partial \beta'} \left\{ -\frac{1}{2\sigma^2} \sum_{t=1}^T (y_t - m - \phi_1 y_{t-1})^2 \right\} \right] \\ &= \lim_{T \rightarrow \infty} \frac{1}{T\sigma^2} E \begin{pmatrix} \sum y_{t-1}^2 & \sum y_{t-1} \\ \sum y_{t-1} & T \end{pmatrix} \\ &= \lim_{T \rightarrow \infty} \frac{1}{T\sigma^2} \begin{pmatrix} T(\gamma_0 + \mu^2) & T\mu \\ T\mu & T \end{pmatrix} \\ &= \frac{1}{\sigma^2} \begin{pmatrix} \gamma_0 + \mu^2 & \mu \\ \mu & 1 \end{pmatrix} \end{aligned}$$

ここで,

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

これより,

$$W^{-1} = \begin{pmatrix} 1 - \phi_1^2 & -(1 - \phi_1^2)\mu \\ -(1 - \phi_1^2)\mu & \sigma^2 + (1 - \phi_1^2)\mu^2 \end{pmatrix}$$

例 2 : MA(1) モデル  $y_t = m + \varepsilon_t - \theta_1 \varepsilon_{t-1}$  の場合

$$\sqrt{T}(\hat{\beta} - \beta) \Rightarrow N(0, W^{-1}), \quad \beta = (\theta_1, m)'$$

$$\begin{aligned} W &= \lim_{T \rightarrow \infty} E \left[ -\frac{1}{T} \frac{\partial^2}{\partial \beta \partial \beta'} \left\{ -\frac{1}{2\sigma^2} \sum_{t=1}^T \varepsilon_t^2 \right\} \right] \\ &= \lim_{T \rightarrow \infty} \frac{1}{T\sigma^2} E \begin{pmatrix} \sum \left( \left( \frac{\partial \varepsilon_t}{\partial \theta_1} \right)^2 + \varepsilon_t \frac{\partial^2 \varepsilon_t}{\partial \theta_1^2} \right) & \sum \left( \varepsilon_t \frac{\partial^2 \varepsilon_t}{\partial m} + \frac{\partial \varepsilon_t}{\partial \theta_1} \frac{\partial \varepsilon_t}{\partial m} \right) \\ \sum \left( \varepsilon_t \frac{\partial^2 \varepsilon_t}{\partial m} + \frac{\partial \varepsilon_t}{\partial \theta_1} \frac{\partial \varepsilon_t}{\partial m} \right) & \sum \left( \left( \frac{\partial \varepsilon_t}{\partial m} \right)^2 + \varepsilon_t \frac{\partial^2 \varepsilon_t}{\partial m^2} \right) \end{pmatrix} \\ &= \lim_{T \rightarrow \infty} \frac{1}{T\sigma^2} E \begin{pmatrix} \sum \left( \left( \frac{\partial \varepsilon_t}{\partial \theta_1} \right)^2 \right) & 0 \\ 0 & \sum \left( \left( \frac{\partial \varepsilon_t}{\partial m} \right)^2 \right) \end{pmatrix} \\ &= \frac{1}{\sigma^2} \begin{pmatrix} V\left(\frac{\varepsilon_{t-1}}{1-\theta_1 L}\right) & 0 \\ 0 & \frac{1}{(1-\theta_1)^2} \end{pmatrix} = \begin{pmatrix} \frac{1}{1-\theta_1^2} & 0 \\ 0 & \frac{1}{\sigma^2(1-\theta_1)^2} \end{pmatrix} \end{aligned}$$

これより,

$$W^{-1} = \begin{pmatrix} 1 - \theta_1^2 & 0 \\ 0 & \sigma^2(1 - \theta_1)^2 \end{pmatrix}$$

(3) Diagnostic Checking: 推定された ARMA モデルの適合度診断

- ・ 残差の自己相関の有無の検定

$$\text{残差: } \hat{\varepsilon}_t = \frac{\hat{\phi}(L)y_t - \hat{m}}{\hat{\theta}(L)}$$

$$\text{残差の自己相関: } \hat{r}_h = \frac{\sum_{t=h+1}^T \hat{\varepsilon}_{t-h} \hat{\varepsilon}_t}{\sum_{t=1}^T \hat{\varepsilon}_t^2}$$

モデルの特定化がよければ，各時差  $h$  に対して

$$\hat{r}_h \rightarrow N\left(0, \frac{1}{T}\right)$$

したがって，有意水準 5% で無相関が受容される受容域は，

$$\left[-1.96 \times \frac{1}{\sqrt{T}}, 1.96 \times \frac{1}{\sqrt{T}}\right]$$

- ・ Portmanteau tests : 複数の時差の自己相関の有無をまとめて検定

$$Q = T \times \sum_{h=1}^K \hat{r}_h^2 : \text{Box-Pierce 統計量}$$

$$\tilde{Q} = T(T+2) \times \sum_{h=1}^K \frac{1}{T-h} \hat{r}_h^2 : \text{Ljung-Box 統計量}$$

無相関の帰無仮説のもとで， $Q$  も  $\tilde{Q}$  も漸近的に自由度  $K-p-q$  の  $\chi^2$  分布にしたがうことから，これらの値が大きいたまに無相関の仮説を棄却する。

- ・ AIC (Akaike's Information Criterion): 赤池情報量基準

$$AIC(p, q) = -2 \times \text{対数尤度の最大値} + 2(p + q)$$

を最小にする  $p$  と  $q$  の組合せからなる ARMA( $p, q$ ) モデルを最適なものとして選択する。

Note. AIC( $p, q$ ) の右辺第 2 項は，パラメータ数  $p, q$  を増やす (モデルを複雑にする) ことに対するペナルティーである。

例 3 : 時系列  $\{y_t\}$  の DGP (Data Generating Process: データ生成過程) を AR(3) 過程

$$y_t = m + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \phi_3 y_{t-3} + \varepsilon_t$$

$$m = 1.5, \quad \phi_1 = 1.55, \quad \phi_2 = -1.1, \quad \phi_3 = 0.4, \quad \sigma^2 = 1$$

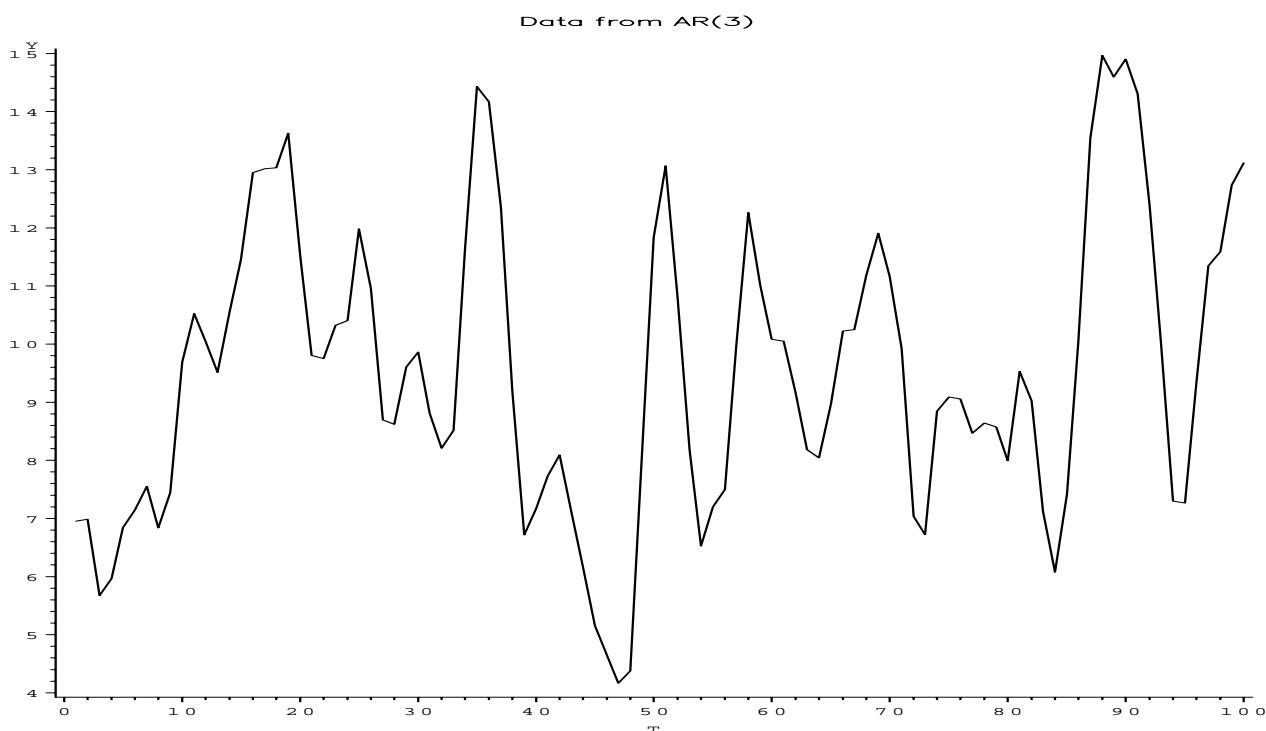
とする。この DGP からの 100 個のデータは次の通りである。

```

6.954 6.986 5.676 5.963 6.841 7.145 7.554 6.836 7.443
9.687 10.525 10.045 9.513 10.548 11.453 12.950 13.017 13.033
13.628 11.518 9.806 9.751 10.324 10.403 11.980 10.957 8.693
8.619 9.603 9.864 8.811 8.208 8.516 11.626 14.430 14.169
12.359 9.201 6.717 7.176 7.728 8.094 7.096 6.164 5.153
4.646 4.165 4.377 8.199 11.834 13.067 10.794 8.178 6.524
7.198 7.499 9.984 12.259 11.009 10.084 10.049 9.159 8.185
8.041 8.971 10.223 10.249 11.185 11.905 11.165 9.920 7.036
6.723 8.843 9.088 9.057 8.467 8.639 8.574 7.993 9.530
9.024 7.118 6.079 7.416 10.048 13.544 14.964 14.595 14.902
14.305 12.382 10.006 7.298 7.267 9.332 11.348 11.587 12.735
13.118

```

$y_t = 1.5 + 1.55y_{t-1} - 1.1y_{t-2} + 0.4y_{t-3} + \varepsilon_t$  からのデータ (T=100)



### ARIMA Procedure

```

Name of variable = Y.
Mean of working series = 9.5265
Standard deviation = 2.495326
Number of observations = 100

```

### Autocorrelations

```

Lag Covar   Corr   -1 9 8 7 6 5 4 3 2 1 0 1 2 3 4 5 6 7 8 9 1
0 6.22665 1.00000 | *****|

```

1	5.0705	0.81432	.	*****
2	2.87933	0.46242	.	*****
3	0.93717	0.15051	.	***
4	-0.1939	-.03114	.	*
5	-0.4237	-.06804	.	*
6	-0.165	-.02650	.	*
7	0.18352	0.02947	.	*
8	0.35806	0.05750	.	*
9	0.28222	0.04532	.	*
10	-0.0769	-.01235	.	
11	-0.5571	-.08946	.	**
12	-1.0289	-.16523	.	***
13	-1.375	-.22083	.	****
14	-1.3197	-.21194	.	****
15	-0.8773	-.14089	.	***
16	-0.3902	-.06267	.	*
17	-0.1233	-.01980	.	
18	-0.0514	-.00825	.	
19	-0.0908	-.01459	.	
20	-0.2099	-.03371	.	*
21	-0.3357	-.05391	.	*
22	-0.5052	-.08114	.	**
23	-0.5076	-.08152	.	**
24	-0.5018	-.08059	.	**

"." marks two standard errors

### Inverse Autocorrelations

Lag	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1		
1	-0.78460			*****									.											
2	0.43806								.				*****											
3	-0.26756								*****				.											
4	0.22597								.				*****											
5	-0.17575								****				.											
6	0.12995								.				***											
7	-0.12302								.	**			.											
8	0.12583								.				***											
9	-0.11133								.	**			.											
10	0.08006								.				**											
11	-0.04236								.	*			.											
12	0.02928								.				*											
13	-0.06218								.	*			.											
14	0.10811								.				**											
15	-0.09698								.	**			.											
16	0.07311								.				*											
17	-0.10064								.	**			.											
18	0.15670								.				***											
19	-0.19502								.	****			.											

20	0.22982		.	*****	
21	-0.26586		*****	.	
22	0.24703		.	*****	
23	-0.14868		.***	.	
24	0.04470		.	*	

Partial Autocorrelations

Lag	Correlation	-1	9	8	7	6	5	4	3	2	1	0	1	2	3	4	5	6	7	8	9	1
1	0.81432									.	*****											
2	-0.59576				*****					*****		.										
3	0.15992									.	***.											
4	0.00141									.	.											
5	0.10376									.	**.											
6	-0.05570									.	*	.										
7	0.03900									.	*	.										
8	-0.03453									.	*	.										
9	-0.00957									.		.										
10	-0.11892									.	**	.										
11	-0.01098									.		.										
12	-0.11374									.	**	.										
13	-0.03743									.	*	.										
14	0.08720									.	**.											
15	0.00033									.		.										
16	-0.07493									.	*	.										
17	-0.01851									.		.										
18	0.05599									.	*	.										
19	-0.01695									.		.										
20	-0.05514									.	*	.										
21	-0.00812									.		.										
22	-0.08410									.	**	.										
23	0.10313									.	**.											
24	-0.20928									*****		.										

Autocorrelation Check for White Noise

To	Chi	Autocorrelations								
Lag	Square	DF	Prob							
6	93.64	6	0.000	0.814	0.462	0.151	-0.031	-0.068	-0.027	
12	98.43	12	0.000	0.029	0.058	0.045	-0.012	-0.089	-0.165	
18	112.39	18	0.000	-0.221	-0.212	-0.141	-0.063	-0.020	-0.008	
24	115.55	24	0.000	-0.015	-0.034	-0.054	-0.081	-0.082	-0.081	

( 1 ) AR(2) モデルをあてはめた場合

Conditional Least Squares Estimation

Approx.

Parameter	Estimate	Std Error	T Ratio	Lag
MU	9.27155	0.37726	24.58	0
AR1,1	1.35004	0.07970	16.94	1
AR1,2	-0.63254	0.08027	-7.88	2

Constant Estimate = 2.6191349  
 Variance Estimate = 1.25947614  
 Std Error Estimate = 1.12226385  
 AIC = 309.811373\*  
 SBC = 317.626884\*  
 Number of Residuals = 100  
 \* Does not include log determinant.

#### Correlations of the Estimates

Parameter	MU	AR1,1	AR1,2
MU	1.000	-0.079	0.025
AR1,1	-0.079	1.000	-0.821
AR1,2	0.025	-0.821	1.000

#### Autocorrelation Check of Residuals

To Lag	Chi Square	DF	Prob	Autocorrelations						
6	5.59	4	0.232	0.137	-0.092	-0.002	-0.001	0.135	0.086	
12	6.12	10	0.805	0.021	-0.004	0.055	-0.028	-0.005	0.021	
18	11.33	16	0.788	-0.124	-0.112	-0.011	0.066	-0.061	-0.086	
24	15.79	22	0.826	-0.010	-0.012	0.050	-0.173	-0.028	0.021	

Model for variable Y

Estimated Mean = 9.27154639

Autoregressive Factors

Factor 1:  $1 - 1.35 B^{**}(1) + 0.63254 B^{**}(2)$

#### ( 2 ) AR(3) モデルをあてはめた場合

#### Conditional Least Squares Estimation

Parameter	Estimate	Approx. Std Error	T Ratio	Lag
MU	8.84347	0.50757	17.42	0
AR1,1	1.52247	0.10110	15.06	1
AR1,2	-0.97221	0.15740	-6.18	2
AR1,3	0.25667	0.10176	2.52	3

Constant Estimate = 1.70736993  
Variance Estimate = 1.20463877  
Std Error Estimate = 1.09756037  
AIC = 306.323481\*  
SBC = 316.744162\*  
Number of Residuals= 100  
\* Does not include log determinant.

Correlations of the Estimates

Parameter	MU	AR1,1	AR1,2	AR1,3
MU	1.000	-0.206	0.149	-0.176
AR1,1	-0.206	1.000	-0.867	0.632
AR1,2	0.149	-0.867	1.000	-0.866
AR1,3	-0.176	0.632	-0.866	1.000

Autocorrelation Check of Residuals

To	Chi	Autocorrelations							
Lag	Square	DF	Prob						
6	1.39	3	0.708	-0.001	-0.020	0.060	-0.082	0.048	0.008
12	3.06	9	0.962	0.001	0.006	0.109	-0.014	0.008	0.051
18	5.83	15	0.982	-0.095	-0.074	-0.002	0.083	-0.037	-0.024
24	11.47	21	0.953	0.035	-0.024	0.114	-0.163	0.024	0.036

Model for variable Y

Estimated Mean = 8.84346631

Autoregressive Factors

Factor 1:  $1 - 1.5225 B^{**}(1) + 0.97221 B^{**}(2) - 0.25667 B^{**}(3)$

(参考 1 ) 例 3 の AR(3) 系列生成のための SAS プログラム

```
filename out 'chap4-1.dat';   データの出力先を確保
data ar3;
do i=1 to 200;                全部で 200 個のデータ
e=rannor(2784322);           正規乱数の発生
lags=sum(1.55*lag1y,-1.1*lag2y,0.4*lag3y,e);
y=1.5+lags;
lag3y=lag2y;lag2y=lag1y;lag1y=y;
if i>100 then output;       後半の 100 個のみを取り出す
end;
data b;set ar3;
```

file out;put y f7.3; 小数点以下 3 桁でデータを chap4-1.dat に書き出す

## (参考 2 ) ARMA モデル分析のための SAS プログラム

```
options ls=65 ps=50; 出力サイズの設定 (ls=列文字数, ps=行文字数)
filename in 'chap4-1.dat'; データの読み込み先を指定
filename graph 'chap4-1.ps'; グラフの出力先を確保
goptions device=pslepsfc gsfmode=replace gsfname=graph; グラフ環境の設定
goptions cback=yellow colors=(rose cyan yellow lilg rose); カラー指定
data ar3; infile in; input y;
t=_n_;
symbol i=join l=1 c=blue v=none; 描くグラフの内容を指定
proc gplot; plot y*t;  GPLOT プロシージャ
title f=simplex h=1.5 'Data from AR(3)'; タイトルの指定
proc arima;  ARIMA プロシージャ
  identify var=y; 分析対象のデータ名を指定
  estimate p=2;  AR(2) を推定
  estimate p=3;  AR(3) を推定
```

## (参考 3 ) ARMA モデル分析のための SHAZAM プログラム

```
sample 1 100
read(chap4-1.dat) y  ファイル chap4-1.dat からデータ y を読みこむ
genr t=time(0)      時間 t=1,2, ... のデータを作成
arima y/plotac plotpac nowide  (identification)
arima y/nar=3 coef=beta resid=ry nowide  (estimation)
gen1 s=sqrt($sig2)  予測
arima y/nar=3 coef=beta fbeg=100 fend=120 sigma=s predict=py resid=res
plot ry t /gnu lineonly device=postscript output=ar3.ps
                                残差のプロット
stop
```