



UNIVERSIDAD COMPLUTENSE  
MADRID

## ECONOMETRÍA APLICADA



Facultad de Ciencias  
Económicas y Empresariales

2

# ANÁLISIS UNIVARIANTE DE SERIES TEMPORALES

## PREVISIÓN CON MODELOS ARIMA

José Alberto Mauricio

Departamento de Análisis Económico y Economía Cuantitativa

## 1. PREVISIÓN CON MODELOS ARIMA - ASPECTOS TEÓRICOS

$$Y_t \sim \text{ARIMA}(p, d, q) \times \text{ARIMA}(P, D, Q)_S$$

**Previsión puntual** de  $Y_t$  en **origen**  $N$  a **horizonte**  $l \geq 1$ :

$$Y_N(l) = E_N[Y_{N+l}], \text{ con } l = 1, 2, \dots \quad [1]$$

**Error de previsión** en **origen**  $N$  a **horizonte**  $l \geq 1$ :

$$\mathcal{E}_N^Y(l) = Y_{N+l} - Y_N(l), \text{ con } l = 1, 2, \dots \quad [2]$$

### EJEMPLO - Previsión con un Modelo AR(1):

1. Escribir el modelo dejando en su lado izquierdo solamente  $Y_t$ :

$$Y_t = \mu + \phi_1 Y_{t-1} + A_t. \quad [3]$$

2. Escribir la expresión [3] del paso 1 en  $t = N + l$ :

$$Y_{N+l} = \mu + \phi_1 Y_{N+l-1} + A_{N+l}. \quad [4]$$

3. Aplicar  $E_N[\cdot]$  a la expresión [4] del paso 2 para obtener  $Y_N(l)$  en [1]:

$$Y_N(l) = \mu + \phi_1 E_N[Y_{N+l-1}] + E_N[A_{N+l}]. \quad [5]$$

4. Particularizar y desarrollar la expresión [5] del paso 3 para  $l = 1, 2, 3, \dots$ :

$$\begin{aligned} l = 1: \quad Y_N(1) &= \mu + \phi_1 \frac{E_N[Y_N]}{Y_N \text{ (R1)}} + \frac{E_N[A_{N+1}]}{0 \text{ (R4)}} \\ &= \mu + \phi_1 Y_N. \end{aligned} \quad [5.1]$$

$$\begin{aligned} l = 2: \quad Y_N(2) &= \mu + \phi_1 \frac{E_N[Y_{N+1}]}{Y_N(1) \text{ (R3)}} + \frac{E_N[A_{N+2}]}{0 \text{ (R4)}} \\ &= \mu + \phi_1 Y_N(1) \\ &= \mu + \phi_1 [\mu + \phi_1 Y_N] = (1 + \phi_1)\mu + \phi_1^2 Y_N. \end{aligned} \quad [5.2]$$

$$Y_N(3) = \mu + \phi_1 \frac{E_N[Y_{N+2}]}{Y_N(2) \text{ (R3)}} + \frac{E_N[A_{N+3}]}{0 \text{ (R4)}}$$

$$l = 3: \quad = \mu + \phi_1 Y_N(2) \quad [5.3]$$

$$= \mu + \phi_1 [(1 + \phi_1)\mu + \phi_1^2 Y_N] = (1 + \phi_1 + \phi_1^2)\mu + \phi_1^3 Y_N.$$

...

5. Generalizar las expresiones [5.1]-[5.3] del paso 4 para cualquier valor del horizonte  $l \geq 1$ :

$$Y_N(1) = \mu + \phi_1 Y_N,$$

$$Y_N(l) = \mu + \phi_1 Y_N(l-1) \text{ para } l \geq 2. \quad [6]$$

La expresión [6] es la **función de previsión** de un modelo AR(1), que también se puede escribir como

$$Y_N(l) = \left( \sum_{i=0}^{l-1} \phi_1^i \right) \mu + \phi_1^l Y_N \text{ para todo } l \geq 1. \quad [7]$$

Cuando  $|\phi_1| < 1$ ,  $Y_N(l) \rightarrow \frac{\mu}{1-\phi_1}$  (la media teórica de un AR(1) estacionario).

6. Particularizar y simplificar los errores de previsión en [2] para  $l = 1, 2, 3, \dots$ , teniendo en cuenta [4] para  $Y_{N+l}$  y [6] para  $Y_N(l)$ :

$$l = 1 \quad \begin{aligned} \mathcal{E}_N^Y(1) &= Y_{N+1} - Y_N(1) \\ &= \mu + \phi_1 Y_N + A_{N+1} - [\mu + \phi_1 Y_N] = A_{N+1}. \end{aligned} \quad [8.1]$$

$$l = 2 \quad \begin{aligned} \mathcal{E}_N^Y(2) &= Y_{N+2} - Y_N(2) \\ &= \mu + \phi_1 Y_{N+1} + A_{N+2} - [\mu + \phi_1 Y_N(1)] \\ &= \phi_1 [Y_{N+1} - Y_N(1)] + A_{N+2} = \phi_1 \mathcal{E}_N^Y(1) + A_{N+2} \\ &= A_{N+2} + \phi_1 A_{N+1}. \end{aligned} \quad [8.2]$$

$$l = 3 \quad \begin{aligned} \mathcal{E}_N^Y(3) &= Y_{N+3} - Y_N(3) \\ &= \mu + \phi_1 Y_{N+2} + A_{N+3} - [\mu + \phi_1 Y_N(2)] \\ &= \phi_1 [Y_{N+2} - Y_N(2)] + A_{N+3} = \phi_1 \mathcal{E}_N^Y(2) + A_{N+3} \\ &= A_{N+3} + \phi_1 A_{N+2} + \phi_1^2 A_{N+1}. \end{aligned} \quad [8.3]$$

...

7. Generalizar las expresiones [8.1]-[8.3] del paso 6 para cualquier valor del horizonte  $l \geq 1$ :

$$\begin{aligned}\mathcal{E}_N^Y(1) &= A_{N+1}, \\ \mathcal{E}_N^Y(l) &= \phi_1 \mathcal{E}_N^Y(l-1) + A_{N+l} \text{ para } l \geq 2,\end{aligned}\tag{9}$$

o bien:

$$\mathcal{E}_N^Y(l) = \sum_{i=0}^{l-1} \phi_1^i A_{N+l-i} \text{ para todo } l \geq 1.\tag{10}$$

Por lo tanto, los errores de previsión tienen esperanza cero y varianza:

$$v(l) = \left( \sum_{i=0}^{l-1} \phi_1^{2i} \right) \sigma_A^2 \text{ para todo } l \geq 1.\tag{11}$$

Cuando  $|\phi_1| < 1$ ,  $v(l) \rightarrow \frac{\sigma_A^2}{1-\phi_1^2}$  (la varianza teórica de un AR(1) estacionario).

En relación con [10]-[11], nótese que en la representación PSI (MA) de un modelo AR(1) ocurre que  $\psi_i = \phi_1^i$  ( $i = 0, 1, 2, \dots$ ).

### Conclusiones Generales Importantes:

- (1) En cualquier modelo estacionario, la función de previsión converge a la media (esperanza) teórica del modelo.
- (2) Los errores de previsión y sus varianzas pueden expresarse en cualquier modelo ARIMA (estacionario o no estacionario) como

$$\begin{aligned}\mathcal{E}_N^Y(l) &= \sum_{i=0}^{l-1} \psi_i A_{N+l-i} \text{ para todo } l \geq 1, \\ v(l) &= \left( \sum_{i=0}^{l-1} \psi_i^2 \right) \sigma_A^2 \text{ para todo } l \geq 1 \left[ \Rightarrow v(1) = \sigma_A^2 \right],\end{aligned}\tag{12}$$

por lo que (3) los errores de previsión siempre tienen esperanza cero, (4) en cualquier modelo estacionario ( $\psi_i \rightarrow 0$ ) las varianzas de los errores de previsión convergen a la varianza teórica del modelo, y (5) en modelos no estacionarios las varianzas de los errores de previsión crecen de manera ilimitada (divergen) con el horizonte de previsión.

### EJEMPLO - La Función de Previsión de un Modelo MA(1):

1. Escribir el modelo dejando en su lado izquierdo solamente  $Y_t$ :

$$Y_t = \mu + A_t - \theta_1 A_{t-1}.\tag{13}$$

2. Escribir la expresión [13] del paso 1 en  $t = N + l$ :

$$Y_{N+l} = \mu + A_{N+l} - \theta_1 A_{N+l-1}. \quad [14]$$

3. Aplicar  $E_N[\cdot]$  a la expresión [14] del paso 2 para obtener  $Y_N(l)$  en [1]:

$$Y_N(l) = \mu + E_N[A_{N+l}] - \theta_1 E_N[A_{N+l-1}]. \quad [15]$$

4. Particularizar y desarrollar la expresión [15] del paso 3 para  $l = 1, 2, 3, \dots$ :

$$l = 1: \quad Y_N(1) = \mu + \frac{E_N[A_{N+1}]}{0 \text{ (R4)}} - \theta_1 \frac{E_N[A_N]}{A_N \text{ (R2)}} = \mu - \theta_1 A_N. \quad [15.1]$$

$$l = 2: \quad Y_N(2) = \mu + \frac{E_N[A_{N+2}]}{0 \text{ (R4)}} - \theta_1 \frac{E_N[A_{N+1}]}{0 \text{ (R4)}} = \mu. \quad [15.2]$$

$$l = 3: \quad Y_N(3) = \mu + \frac{E_N[A_{N+3}]}{0 \text{ (R4)}} - \theta_1 \frac{E_N[A_{N+2}]}{0 \text{ (R4)}} = \mu. \quad [15.3]$$

...

5. Generalizar las expresiones [15.1]-[15.3] del paso 4 para cualquier valor del horizonte  $l \geq 1$ :

$$Y_N(1) = \mu - \theta_1 A_N, \quad Y_N(l) = \mu \text{ para } l \geq 2. \quad [16]$$

### EJEMPLO - Previsión con un Paseo Aleatorio:

Considerando un Paseo Aleatorio como un modelo AR(1) con  $\phi_1 = 1$ ,

$$Y_t = \mu + Y_{t-1} + A_t,$$

los resultados principales del ejemplo sobre el modelo AR(1), particularizados para este caso ( $\phi_1 = 1$ ), son los siguientes:

$$[7] \Rightarrow \quad Y_N(l) = \left( \sum_{i=0}^{l-1} 1^i \right) \mu + Y_N = l\mu + Y_N \text{ para todo } l \geq 1,$$

$$[11] \Rightarrow \quad v(l) = \left( \sum_{i=0}^{l-1} 1^{2i} \right) \sigma_A^2 = l \sigma_A^2 \text{ para todo } l \geq 1.$$

## La Función de Previsión de un Modelo ARIMA:

$$\phi(B)\Phi(B^S)[\nabla^d\nabla_S^D Y_t - \mu_W] = \theta(B)\Theta(B)A_t. \quad [17.1]$$

$$\Phi^*(B)Y_t = \mu + \Theta^*(B)A_t, \quad [17.2]$$

$$\begin{aligned} \Phi^*(B) &= \phi(B)\Phi(B^S)\nabla^d\nabla_S^D = 1 - \sum_{i=1}^{p^*} \Phi_i^* B^i, \text{ con} \\ p^* &= (p+d) + (P+D) \times S, \end{aligned} \quad [17.2.1]$$

$$\begin{aligned} \Theta^*(B) &= \theta(B)\Theta(B^S) = 1 - \sum_{i=1}^{q^*} \Theta_i^* B^i, \text{ con} \\ q^* &= q + Q \times S, \end{aligned} \quad [17.2.2]$$

$$\mu = [\phi(1)\Phi(1)] \times \mu_W. \quad [17.2.3]$$

$$[17.2] \Rightarrow Y_t = \mu + \sum_{i=1}^{p^*} \Phi_i^* Y_{t-i} + A_t - \sum_{i=1}^{q^*} \Theta_i^* A_{t-i}. \quad [17.3]$$

$$[17.3] \Rightarrow Y_{N+l} = \mu + \sum_{i=1}^{p^*} \Phi_i^* Y_{N+l-i} + A_{N+l} - \sum_{i=1}^{q^*} \Theta_i^* A_{N+l-i}. \quad [18]$$

$$[18] \Rightarrow Y_N(l) = E_N[Y_{N+l}] = \mu + \sum_{i=1}^{p^*} \Phi_i^* E_N[Y_{N+l-i}] + E_N[A_{N+l}] - \sum_{i=1}^{q^*} \Theta_i^* E_N[A_{N+l-i}] \quad (l = 1, 2, \dots), \quad [19]$$

con:

$$\begin{aligned} R1 : E_N[Y_j] &= Y_j \text{ si } j \leq N, \\ R2 : E_N[A_j] &= A_j \text{ si } j \leq N, \\ R3 : E_N[Y'_j] &= Y'_N(j-N) \text{ si } j > N, \\ R4 : E_N[A_j] &= E[A_j] = 0 \text{ si } j > N. \end{aligned} \quad [20]$$

## 2. PREVISIÓN CON MODELOS ARIMA - CÁLCULOS

### EJEMPLO - Cálculo de Previsiones Puntuales con un Modelo AR(1):

$$[6] \Rightarrow \hat{y}_N(1) = \hat{\mu} + \hat{\phi}_1 y_N, \hat{y}_N(l) = \hat{\mu} + \hat{\phi}_1 \hat{y}_N(l-1) \text{ para } l \geq 2.$$

### EJEMPLO - Cálculo de Previsiones Puntuales con un Modelo MA(1):

$$[16] \Rightarrow \hat{y}_N(1) = \hat{\mu} - \hat{\theta}_1 \hat{a}_N, \hat{y}_N(l) = \hat{\mu} \text{ para } l \geq 2.$$

### Cálculo de Previsiones Puntuales con un Modelo ARIMA:

$$[19] \Rightarrow \hat{y}_N(l) = \hat{E}_N[Y_{N+l}] = \hat{\mu} + \sum_{i=1}^{p^*} \hat{\Phi}_i^* \hat{E}_N[Y_{N+l-i}] + \hat{E}_N[A_{N+l}] - \sum_{i=1}^{q^*} \hat{\Theta}_i^* \hat{E}_N[A_{N+l-i}] \quad (l = 1, 2, \dots), \quad [21]$$

con:

$$[20] \Rightarrow \begin{aligned} \widehat{R1} &: \hat{E}_N[Y_j] = y_j \quad \text{si } j \leq N, \\ \widehat{R2} &: \hat{E}_N[A_j] = \hat{a}_j \quad \text{si } j \leq N, \\ \widehat{R3} &: \hat{E}_N[Y_j] = \hat{y}_N(j - N) \quad \text{si } j > N, \\ \widehat{R4} &: \hat{E}_N[A_j] = 0 \quad \text{si } j > N. \end{aligned}$$

### Varianzas Estimadas de los Errores de Previsión:

$$[12] \Rightarrow \hat{v}(l) = \left( \sum_{i=0}^{l-1} \hat{\psi}_i^2 \right) \hat{\sigma}_A^2 \quad \text{para todo } l \geq 1 \left[ \Rightarrow \hat{v}(1) = \hat{\sigma}_A^2 \right]. \quad [22]$$

### Estimación de Intervalos de Confianza y Probabilidades:

$$\begin{aligned} \widehat{IC}_{95\%}[Y_{N+l}] &= \left[ \hat{y}_N(l) \mp 1.96\sqrt{\hat{v}(l)} \right], \\ \widehat{Pr}[Y_{N+l} \leq b] &= \Pr \left[ N(0, 1) \leq \frac{b - \hat{y}_N(l)}{\sqrt{\hat{v}(l)}} \right] \quad (l = 1, 2, \dots). \end{aligned} \quad [23]$$

### Cálculos referidos a la Transformación Logarítmica:

Si una serie original  $x_t$  requiere una transformación logarítmica para estabilizar su dispersión, entonces los cálculos en [21]-[23] se refieren a la serie  $y_t = \ln(x_t)$ . Por lo tanto, cada previsión puntual para la serie original  $x_t = \exp\{y_t\}$  (con  $\exp\{y_t\} = e^{y_t}$ ) se puede calcular simplemente como  $\hat{x}_N(l) = \exp\{\hat{y}_N(l)\}$ , y el intervalo de confianza correspondiente como  $\left[ \exp\{\hat{y}_N(l) - 1.96\sqrt{\hat{v}(l)}\}, \exp\{\hat{y}_N(l) + 1.96\sqrt{\hat{v}(l)}\} \right]$ , que no es simétrico con respecto a  $\hat{x}_N(l)$ . Un intervalo de confianza que sí es simétrico puede calcularse como  $\left[ \hat{x}_N(l) \mp 1.96\sqrt{\hat{w}(l)} \right]$ , donde  $\hat{w}(l) = \hat{x}_N(l)^2 \times \hat{v}(l)$  es una aproximación [\*] a la varianza estimada del error de previsión asociado con la serie  $x_t$  original:

$$\begin{aligned} \hat{x}_N(l) &= \exp\{\hat{y}_N(l)\}, \quad \hat{w}(l) = \hat{x}_N(l)^2 \times \hat{v}(l), \\ \widehat{IC}_{95\%}[X_{N+l}] &= \left[ \hat{x}_N(l) \mp 1.96\sqrt{\hat{w}(l)} \right], \\ \widehat{Pr}[X_{N+l} \leq b] &= \Pr \left[ N(0, 1) \leq \frac{b - \hat{x}_N(l)}{\sqrt{\hat{w}(l)}} \right] \quad (l = 1, 2, \dots). \end{aligned}$$

[\*] Una aproximación de Taylor de grado 1 (lineal) a la función  $\ln(x)$  alrededor de  $x_0$  proporciona lo siguiente:

$$\ln(x) \cong \ln(x_0) + \frac{d \ln(x_0)}{dx} (x - x_0) = \ln(x_0) + \frac{1}{x_0} (x - x_0), \text{ o bien}$$

$$x - x_0 \cong x_0 \times [\ln(x) - \ln(x_0)].$$

Con  $x = X_{N+l}$ ,  $x_0 = X_N(l)$ , la expresión anterior implica que

$$\frac{X_{N+l} - X_N(l)}{\mathcal{E}_N^X(l)} \cong X_N(l) \times \left\{ \frac{Y_{N+l}}{\ln(X_{N+l})} - \frac{Y_N(l)}{\ln[X_N(l)]} \right\}.$$

Por lo tanto,

$$\text{Vâr} \left[ \mathcal{E}_N^X(l) \right] \cong \hat{x}_N(l)^2 \times \underbrace{\text{Vâr} \left[ \mathcal{E}_N^Y(l) \right]}_{\hat{v}(l)} = \hat{x}_N(l)^2 \times \hat{v}(l) = \hat{w}(l).$$

### 3. EJEMPLO 1 - ST17 : Y = BJRA

#### MODELO M1: ARMA(1,1) CON MEDIA (TÉRMINO CONSTANTE)

Dependent Variable: Y				
Method: Least Squares				
Sample(adjusted): 2 197				
Included observations: 196 after adjusting endpoints				
Convergence achieved after 11 iterations				
Backcast: 1				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	17.11141	0.110643	154.6537	0.0000
AR(1)	0.917624	0.041351	22.19102	0.0000
MA(1)	-0.608054	0.081951	-7.419684	0.0000
R-squared	0.391229	Mean dependent var	17.06276	
Adjusted R-squared	0.384920	S.D. dependent var	0.400244	
S.E. of regression	0.313900	Akaike info criterion	0.535700	
Sum squared resid	19.01686	Schwarz criterion	0.585876	
Log likelihood	-49.49864	F-statistic	62.01609	
Durbin-Watson stat	1.875472	Prob(F-statistic)	0.000000	

$$(1 - 0.917624B) (y_t - 17.11141) = (1 - 0.608054B) \hat{a}_t,$$

$$(0.041351) \quad (0.11064) \quad (0.081951)$$

$$n = 196, \hat{\sigma}_A = 0.3139, \text{AIC} = 0.5357, \text{BIC} = 0.5859.$$



### MODELO M2: IMA(1,1)

Dependent Variable: D( Y )				
Method: Least Squares				
Sample(adjusted): 2 197				
Included observations: 196 after adjusting endpoints				
Convergence achieved after 11 iterations				
Backcast: 1				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
MA(1)	-0.702478	0.051036	-13.76448	0.0000
R-squared	0.264356	Mean dependent var	0.002041	
Adjusted R-squared	0.264356	S.D. dependent var	0.370303	
S.E. of regression	0.317607	Akaike info criterion	0.549087	
Sum squared resid	19.67052	Schwarz criterion	0.565812	
Log likelihood	-52.81057	Durbin-Watson stat	1.798177	

$$\nabla y_t = (1 - 0.702478B) \hat{a}_t,$$

$$(0.051036)$$

$$n = 196, \hat{\sigma}_A = 0.3176, AIC = 0.5491, BIC = 0.5658.$$

### MODELO M1

$$(1 - \phi_1 B)(Y_t - \mu_Y) = (1 - \theta_1 B)A_t \Leftrightarrow Y_t = [(1 - \phi_1)\mu_Y] + \phi_1 Y_{t-1} + A_t - \theta_1 A_{t-1}.$$

$$y_t = 1.40957 + 0.917624 \times y_{t-1} + \hat{a}_t - 0.608054 \times \hat{a}_{t-1}.$$

$$Y_{197}(1) = E_{197}[Y_{198}] =$$

$$= \mu + \phi_1 E_{197}[Y_{197}] + E_{197}[A_{198}] - \theta_1 E_{197}[A_{197}] = \mu + \phi_1 Y_{197} - \theta_1 A_{197}.$$

$$\hat{y}_{197}(1) = \hat{E}_{197}[Y_{198}] = \hat{\mu} + \hat{\phi}_1 \times y_{197} - \hat{\theta}_1 \times \hat{a}_{197}$$

$$= 1.40957 + 0.917624 \times 17.4 - 0.608054 \times (-0.034957) = 17.39748.$$

$$Y_{197}(2) = E_{197}[Y_{199}] =$$

$$= \mu + \phi_1 E_{197}[Y_{198}] + E_{197}[A_{199}] - \theta_1 E_{197}[A_{198}] = \mu + \phi_1 Y_{197}(1).$$

$$\hat{y}_{197}(2) = \hat{E}_{197}[Y_{199}] = \hat{\mu} + \hat{\phi}_1 \times \hat{y}_{197}(1)$$

$$= 1.40957 + 0.917624 \times 17.39748 = 17.37392.$$

$$Y_{197}(3) \equiv E_{197}[Y_{200}] =$$

$$= \mu + \phi_1 E_{197}[Y_{199}] + E_{197}[A_{200}] - \theta_1 E_{197}[A_{199}] = \mu + \phi_1 Y_{197}(2).$$

$$\hat{y}_{197}(3) \equiv \hat{E}_{197}[Y_{200}] = \hat{\mu} + \hat{\phi}_1 \times \hat{y}_{197}(2)$$

$$= 1.40957 + 0.917624 \times 17.37392 = 17.35229.$$

## MODELO M2

$$\nabla Y_t = (1 - \theta_1 B)A_t \Leftrightarrow Y_t = Y_{t-1} + A_t - \theta_1 A_{t-1}.$$

$$y_t = y_{t-1} + \hat{a}_t - 0.702478 \times \hat{a}_{t-1}.$$

$$\begin{aligned} Y_{197}(1) &= E_{197}[Y_{198}] = \\ &= E_{197}[Y_{197}] + E_{197}[A_{198}] - \theta_1 E_{197}[A_{197}] = Y_{197} - \theta_1 A_{197}. \end{aligned}$$

$$\hat{y}_{197}(1) = \hat{E}_{197}[Y_{198}] = y_{197} - \hat{\theta}_1 \times \hat{a}_{197} = 17.4 - 0.702478 \times (-0.149070) = 17.50472.$$

$$\begin{aligned} Y_{197}(2) &= E_{197}[Y_{199}] = \\ &= E_{197}[Y_{198}] + E_{197}[A_{199}] - \theta_1 E_{197}[A_{198}] = Y_{197}(1). \end{aligned}$$

$$\hat{y}_{197}(2) = \hat{E}_{197}[Y_{199}] = \hat{y}_{197}(1) = 17.50472.$$

$$\begin{aligned} Y_{197}(3) &= E_{197}[Y_{200}] = \\ &= E_{197}[Y_{199}] + E_{197}[A_{200}] - \theta_1 E_{197}[A_{199}] = Y_{197}(2). \end{aligned}$$

$$\hat{y}_{197}(3) = \hat{E}_{197}[Y_{200}] = \hat{y}_{197}(2) = 17.50472.$$

## 4. CRITERIOS DE EVALUACIÓN DE PREVISIONES

$$\begin{array}{l} \left[ \begin{array}{l} \text{Muestra} \\ \text{de} \\ \text{modelización} \end{array} \right. \left. \begin{array}{l} y_1 \\ y_2 \\ \vdots \\ y_N \end{array} \right] \rightarrow \text{Modelo} \rightarrow \text{Previsiones: } \hat{y}_N(1), \dots, \hat{y}_N(L). \\ \left[ \begin{array}{l} \text{Muestra} \\ \text{de} \\ \text{previsión} \end{array} \right. \left. \begin{array}{l} y_{N+1} - \hat{y}_N(1) = \hat{e}_N(1) \\ y_{N+2} - \hat{y}_N(2) = \hat{e}_N(2) \\ \vdots \\ y_{N+L} - \hat{y}_N(L) = \hat{e}_N(L) \end{array} \right] \rightarrow \text{Errores: } \hat{e}_N(1), \dots, \hat{e}_N(L). \end{array}$$

Muestra disponible completa

*Root Mean Squared Error:*

$$RMSE = \sqrt{\frac{1}{L} \sum_{l=1}^L \hat{e}_N(l)^2}. \quad [24]$$

*Mean Absolute Error:*

$$MAE = \frac{1}{L} \sum_{l=1}^L |\hat{e}_N(l)|. \quad [25]$$

*Mean Absolute Percentage Error:*

$$MAPE = 100 \times \left( \frac{1}{L} \sum_{l=1}^L \left| \frac{\hat{e}_N(l)}{y_{N+l}} \right| \right). \quad [26]$$

## 5. EJEMPLO 2 - ST14 : Y = LOG( VIVIN ) 1989:01 1999:12

### MODELO M1: ARI(2,1)×IMA(1,1)<sub>12</sub>

$$(1 + 0.5404B + 0.4583B^2)\nabla\nabla_{12}y_t = (1 - 0.8809B^{12})\hat{a}_t,$$

$$(0.0831) \quad (0.0831) \quad (0.0242)$$

$n = 117, \hat{\sigma}_A = 0.1359, AIC = -1.1282, BIC = -1.0574.$

### MODELO M2: IMA(1,1)×IMA(1,1)<sub>12</sub>

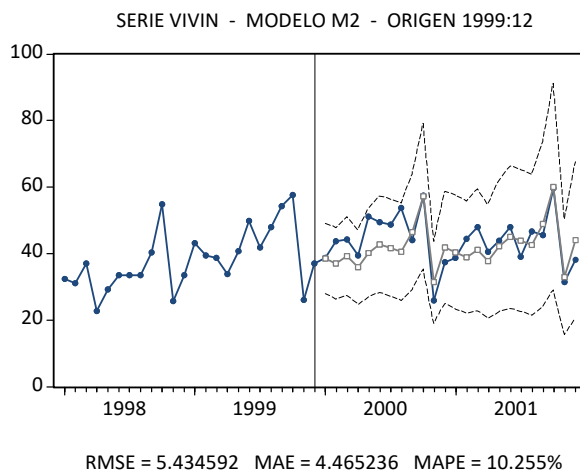
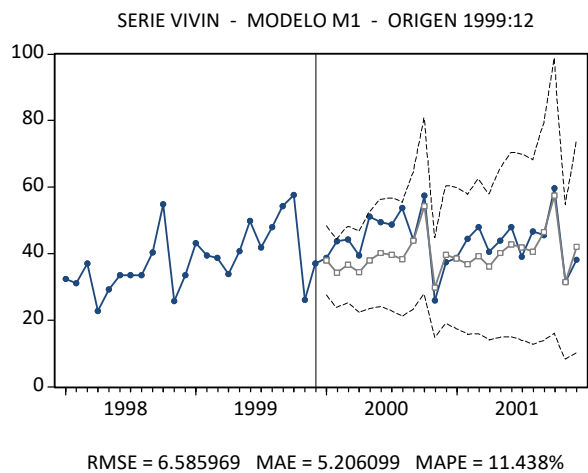
$$\nabla\nabla_{12}y_t = (1 - 0.6753B)(1 - 0.8918B^{12})\hat{a}_t,$$

$$(0.0700) \quad (0.0236)$$

$n = 119, \hat{\sigma}_A = 0.1371, AIC = -1.1194, BIC = -1.0727.$

$$\nabla\nabla_{12} = (1 - B)(1 - B^{12}) = 1 - B - B^{12} + B^{13},$$

$$y_t = y_{t-1} + y_{t-12} - y_{t-13} + \hat{a}_t - 0.6753\hat{a}_{t-1} - 0.8918\hat{a}_{t-12} + 0.6022\hat{a}_{t-13}.$$



## OPERACIONES CON EIEWS

*Introducción al Uso de EViews 4.1 (2021 J.A.M.): Sección 19 pp. 105-107.*