

Econometría II



ARIMA B

Carlos A. Yanes Guerra

2024-I

Preguntas de las sesiones anteriores?

Recordeis

1. Es **estacionario** o **no estacionario**?
2. Qué tipo de **autocorrelación** manifiestan los patrones de la serie?
3. Posee una variación **estacional**?
4. Existe algún desplazamiento estructural?

Procesos MA

Los MA(q) son procesos que indican que la serie de tiempo depende de los errores pasados. Al igual que los AR(p), sirven para modelar y pronosticar desde el modelo univariado los periodos futuros


Algunas características de este proceso son:

- Un MA(1) se representa como: $y_t = \mu + \epsilon_t + \theta_1\epsilon_{t-1}$
- Un MA(2) se representa como: $y_t = \mu + \epsilon_t + \theta_1\epsilon_{t-1} + \theta_2\epsilon_{t-2}$
- Un MA(q) se representa como: $y_t = \mu + \epsilon_t + \theta_1\epsilon_{t-1} + \dots + \theta_q\epsilon_{t-q}$

Procesos MA

Existe en series de tiempo un *teorema* y es el que nos dice que cualquier serie que es **estacionaria** puede representarse mediante un **MA(q)** de orden infinito. Esto lo dice Wold(1936).

Simulación de MA Infinito



Procesos MA

Determine si el Proceso MA es **estacionario** en **media** y **varianza**

$$y_t = a + \theta_1 \epsilon_{t-1} + \epsilon_t$$

$$E[y_t] = E[a + \theta_1 \epsilon_{t-1} + \epsilon_t]$$

$$E[y_t] = a + \theta_1 E[\epsilon_{t-1}] + E[\epsilon_t]$$

Recordemos que por **ruido blanco** eso es $\sim (0, \sigma^2)$

$$\boxed{E[y_t] = a}$$

No depende de (t) .

Procesos MA

Vamos ahora con la **varianza**:

$$y_t = a + \theta_1 \epsilon_{t-1} + \epsilon_t$$

$$\text{Var}[y_t] = \text{Var}[a + \theta_1 \epsilon_{t-1} + \epsilon_t]$$

$$\text{Var}[y_t] = \theta_1^2 \text{Var}[\epsilon_{t-1}] + \text{Var}[\epsilon_t]$$

Recordemos nuevamente que por **ruido blanco** eso es $\sim (0, \sigma^2)$

$$\text{Var}[y_t] = \theta_1^2 \sigma^2 + \sigma^2$$

$$\text{Var}[y_t] = \sigma^2 (\theta_1^2 + 1)$$

Tambien piense que la **varianza** se escribe como γ_0

$$\boxed{\gamma_0 = \sigma^2 (\theta_1^2 + 1)}$$

Procesos MA

El asunto de la **covarianza** permite gráficar e identificar los procesos concernientes a la autocorrelación y por ende tener las funciones de autocorrelación **simple** y **parcial**.

$$\text{cov}[y_t, y_{t-s}] = \theta_1^2 \text{cov}[\epsilon_{t-1}, \epsilon_{(t-s)-1}] + \text{cov}[\epsilon_t, \epsilon_{t-s}]$$

$$\gamma_0 = \theta_1^2 \sigma^2 + \sigma^2$$

Entonces si $s = -1, 1 \Rightarrow \gamma_1 = \theta_1 \sigma^2$

Entonces si $s = 2 \Rightarrow \gamma_2 = 0$


Entonces si $s = 3 \Rightarrow \gamma_3 = 0$

Dicho mejor


$$\rho = \begin{cases} 1 & \text{si } s = 0 \\ \frac{\theta_1}{1+\theta_1^2} & \text{si } s = 1, -1 \\ 0 & \text{de otro lado} \end{cases}$$

Procesos MA


ACF de un Proceso MA(1) con $\phi = 0.4$




ACF de un Proceso MA(1) con $\phi = 0.6$



ACF de un Proceso MA(1) con $\phi = -0.6$




ACF de un Proceso MA(1) con $\phi = 2$




Procesos MA

✈ Preguntemos algo: Intente identificar el orden del siguiente modelo

ACF de prueba




PACF de prueba




Procesos MA


ACF de AR(1)



ACF de MA(1)



ACF de ARMA(1,1)



Procesos MA

- Identificar los modelos por sus respectivas **ACF** y **PACF** es mejor que estar haciendo 1000 modelos y encontrar el modelo con menor criterio AIC o BIC.
- Dentro de los criterios, recordando nuevamente su formulación pero en términos de varianza:

Criterio de AKAIKE: Es el menos estricto de todos, no es **consistente** pero si eficiente.

$$AIC = \ln(\sigma^2) + \frac{2k}{T}$$

Criterio de BAYES: Es el mejor, castiga (sobre parametrización), es consistente pero no muy eficiente (no robusto en residuos).

$$BIC = \ln(\sigma^2) + \frac{k}{T} \ln(T)$$

Donde (σ^2) es la varianza de los errores (residuos del modelo), (k) el número de parámetros $(p+q+1)$ si se incluye la constante y de $(p+q)$ si se omite y por último (T) es el numero de observaciones.

Procesos MA

Ejercicio 1:

Qué modelo es mejor?

# Lags	AIC	BIC	R2
0	1.095	1.076	0.000
1	1.067	1.030	0.056
2	0.955	0.900	0.181
3	0.957	0.884	0.203
4	0.986	0.895	0.204
5	1.016	0.906	0.204
6	1.046	0.918	0.205

R./ Note que depende que quiere ver el investigador. Si desea muchos rezagos lo mejor es tomar entonces el \bar{R}_{adj}^2 . El BIC penaliza la sobreparametrización y el AIC es un poco mas intermedio.

Otras consideraciones de los Procesos MA



Invertibilidad

Un proceso MA es invertible si:

Considere el modelo MA:

$$y_t - \mu = (1 + \theta L)\epsilon_t$$

$$E(\epsilon_t, \epsilon_s) = \begin{cases} \sigma^2 & \text{si } s = t \\ 0 & \text{de otro lado} \end{cases}$$

$$\text{Si } |\theta| < 1$$

$$(1 + \theta L)^{-1}(y_t - \mu) = \epsilon_t$$

$$(1 - \theta L + \theta^2 L^2 - \theta^3 L^3 + \dots)(y_t - \mu) = \epsilon_t$$

Es Invertible AR(p) ✓

Invertibilidad

Dentro de las condiciones de invertibilidad también debe tenerse en cuenta las **raíces complejas** y esto es $1 + \theta_1 z + \theta_2 z^2 + \dots + \theta_q z^q$, en un plano complejo deben caer por fuera del círculo unitario

Esto es condicionante de:

- Para procesos de $q = 1$: $-1 < \theta_1 < 1$
- Para procesos de $q = 2$: $-1 < \theta_2 < 1$ pero $\theta_2 + \theta_1 > -1$ o $\theta_1 - \theta_2 < 1$
- Para procesos de $q = 3$ es mas complejo... pero los softwares responden por ello.

Con respecto a los modelos Diferenciados!!

Ejemplo

Punto: Suponga que le ha tocado hacer un modelo y pronóstico para **inflación**. El resultado de todo, término siendo:

$$\Delta Inf_t = -0.0145 - .3215\Delta inf_{t-1}$$

$Inf_{2021:3} = 6.53\%$ es la inflación del respectivo año 2021 en el mes 3.

La inflación del siguiente periodo fué $Inf_{2021:4} = 6.56\%$. Note que si diferenciamos tendremos

$$Inf_{2021:4} - Inf_{2021:3} = 0.029$$

Reemplazamos ese valor en nuestro modelo original:

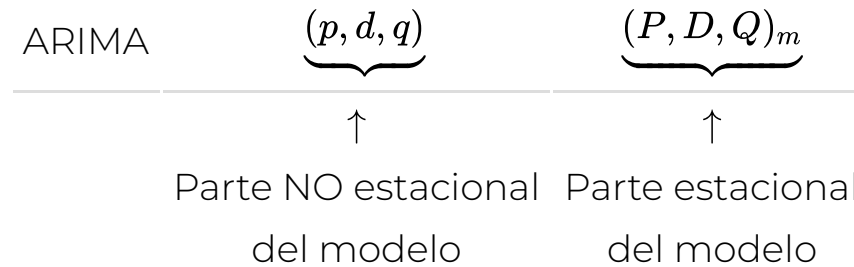
$$\Delta Inf_t = -0.0145 - .3215(0.029) = -0.02382$$

Lo que usando el último valor del mes:

$$Inf_{2021:3} + \Delta_{2021:4} \Rightarrow 6.56 - 0.02382 = 6.54\%$$

Modelo SARIMA

Modelo Sarima



Donde m = número de observaciones por año.

Los modelos SARIMA, permiten no tener raíces estacionales. Recuerde que no ser **estacionario** tiene muchos problemas a la hora de pronosticar.

Modelo Sarima

La **parte estacional** de un modelo AR o MA se verá en los rezagos estacionales de PACF y ACF.

Un $ARIMA(0, 0, 0)(0, 0, 1)_{12}$ mostrará:

- Un pico en el lag 12 del ACF pero ningún otro pico significativo.
- El PACF mostrará un decaimiento exponencial en los rezagos estacionales; es decir, en los rezagos **12, 24, 36, ...**

Un $ARIMA(0, 0, 0)(1, 0, 0)_{12}$ mostrará:

- Decaimiento exponencial en los **rezagos estacionales** de la ACF
- Un único pico significativo en el lag 12 en el PACF.

Bibliografía

- ☰ Chatfield, C. (2000). *Time-series forecasting*. CRC press.
- ☰ Hyndman, R.J., & Athanasopoulos, G. (2021). *Forecasting: principles and practice*, 3rd edition, OTexts: Melbourne, Australia.
- ☰ Shumway, R., & Stoffer, D. (2019). *Time series: a data analysis approach using R*. CRC Press.
- ☰ Campo, J. Notas de clase (MIMEO)

¡Gracias!

Modelos MA

Seguimos aprendiendo



 Syllabus/ Curso

 @keynes37

 cayanes@uninorte.edu.co