

# MACROECONOMETRÍA

## Tema 2: Series temporales

Segundo Cuatrimestre (curso 2006/07), Depto. de Economía, UC3M

Profesor: Genaro Sucarrat

(Coordinador: Juan J. Dolado)

## Conceptos fundamentales:

- Esperanzas condicionales vs. esperanzas incondicionales
- **Definición: Autocovarianza de retardo  $k$ .** La autocovarianza (“autocovariance”) de retardo  $k$  de un proceso estocástico, denotado  $Cov(x_t, x_{t-k})$ , se define como

$$E[(x_t - \mu_t)(x_{t-k} - \mu_{t-k})],$$

donde  $\mu_t = E(x_t)$  y  $\mu_{t-k} = E(x_{t-k})$

## Conceptos fundamentales (cont.):

- **Definición: Estacionariedad débil.** Un proceso estocástico es estacionario débil ("weakly stationary") o estacionario en covarianza ("covariance stationary") si:

$$E(x_t) = \mu \text{ para todo } t$$

$$E[(x_t - \mu)(x_{t-k} - \mu)] = \gamma_k \text{ para todo } t$$

*Nota 1:* Efectivamente esto significa que ni la media  $E(x_t)$  ni la covarianza  $E[(x_t - \mu)(x_{t-k} - \mu)]$  dependen del tiempo  $t$ .

*Nota 2:* Estacionariedad débil es una propiedad *no condicional*. Por ejemplo,  $E(x)$  es la media no condicional y  $E(x|y)$  es la media condicional en  $y$ , y  $Cov(x, y)$  es la covarianza no condicional y  $Cov(x, y|z)$  es la covarianza condicional en  $z$ .

*Nota 3:* Cuando  $k = 0$  entonces  $E[(x_t - \mu)(x_{t-k} - \mu)]$  es igual a la varianza  $E(x_t - \mu)^2 = Var(x_t)$

## Conceptos fundamentales (cont.):

- **Definición: Ruido blanco.** Se dice que el proceso  $\{\epsilon_t\}$  es ruido blanco (“white noise”) si:

$$\begin{aligned} E(\epsilon_t) &= 0 \\ \text{Para todo } i \neq j: \quad \text{Cov}(\epsilon_i \epsilon_j) &= 0 \\ \text{Var}(\epsilon_t) &= E(\epsilon_t^2) = \sigma^2 \end{aligned}$$

- Notación:  $\epsilon_t \sim WN$
- Ruido blanco Gaussiano: Para todo  $t$ ,  $\epsilon_t \sim N(0, \sigma^2)$

## Modelos ARMA:

- **Definición: Modelo ARMA.** Un modelo autoregresivo-media móvil (“autoregressive moving average”—ARMA) de una serie estacionaria débil  $\{y_t\}$  tiene la forma:

$$y_t = \phi_0 + \sum_{i=1}^p \phi_i y_{t-i} + \sum_{j=0}^q \theta_j \epsilon_{t-j},$$

donde el proceso  $\{\epsilon_t\}$  es *ruido blanco*.

- Este modelo se denota como  $ARMA(p, q)$ , y normalmente se normaliza  $\theta_0$  a 1
- *Nota:* si hay que diferenciar la serie para que sea estacionaria entonces a veces se usa la terminología  $ARIMA(p, d, q)$ , donde  $d$  es el orden de integración

## Modelos ARMA (cont.):

- Con  $p = 0$  obtendremos el modelo MA( $q$ ):

$$y_t = \phi_0 + \sum_{j=0}^q \theta_j \epsilon_{t-j} = \phi_0 + (1 + \theta_1 L + \dots + \theta_q L^q) \epsilon_t$$

donde  $\{\epsilon_t\}$  es ruido blanco y donde  $\theta_0 = 1$

$$\Rightarrow \mu = E(y_t) = \phi_0$$

$$\Rightarrow \gamma_0 = \text{Var}(y_t) = (1 + \theta_1^2 + \dots + \theta_q^2) \sigma^2$$

$$\Rightarrow \gamma_k = \text{Cov}(y_t, y_{t-k}) = \begin{cases} (\theta_k + \theta_{k+1} \theta_1 + \dots + \theta_q \theta_{q-k}) \sigma^2, & k = 1, \dots, q \\ 0 & \text{para } k > q \end{cases}$$

- ¿Es el modelo MA( $q$ ) estacionario? Si

## Modelos ARMA (cont.):

- Con  $p = 0$  y  $q \rightarrow \infty$ , obtendremos el modelo  $MA(\infty)$ :

$$y_t = \phi_0 + \sum_{j=0}^{\infty} \theta_j \epsilon_{t-j} = \phi_0 + (1 + \theta_1 L + \theta_2 L^2 + \dots) \epsilon_t$$

donde  $\{\epsilon_t\}$  es ruido blanco y donde  $\theta_0 = 1$

- ¿Cómo podemos saber si  $MA(\infty)$  es un proceso estacionario?  
Cualquiera de las condiciones siguientes es suficiente:

$$a) \quad \sum_{j=0}^{\infty} \theta_j^2 < \infty$$

↑

$$b) \quad \sum_{j=0}^{\infty} |\theta_j| < \infty$$

## Modelos ARMA (cont.):

- Esperanzas incondicionales del  $MA(\infty)$ :

$$\Rightarrow \mu = \phi_0$$

$$\Rightarrow \gamma_0 = \sigma^2(\theta_0^2 + \theta_1^2 + \theta_2^2 + \dots)$$

$$\Rightarrow \gamma_k = \sigma^2(\theta_k\theta_0 + \theta_{k+1}\theta_1 + \theta_{k+2}\theta_2 + \dots)$$

- Implicación: todos los modelos  $MA(q)$  con  $q < \infty$  son estacionarios

## Modelos ARMA (cont.):

- Con  $q = 0$  obtendremos el modelo  $AR(p)$ :

$$y_t = \phi_0 + \sum_{i=1}^p \phi_i y_{t-i} + \epsilon_t = \phi_0 + (\phi_1 L + \dots + \phi_p L^p) y_t + \epsilon_t$$

- Si todas las raíces características del polinomio  $(1 - \phi_1 L - \dots - \phi_p L^p)$  están fuera del círculo unidad, entonces:

$\Rightarrow$  El modelo  $AR(p)$  se puede escribir/representar como un modelo  $MA(\infty)$ :

$$y_t = \frac{\phi_0}{1 - \phi_1 L - \dots - \phi_p L^p} + \frac{1}{1 - \phi_1 L - \dots - \phi_p L^p} \epsilon_t$$

$\Rightarrow$  El modelo  $AR(p)$  es estable y estacionario

## Modelos ARMA (cont.):

- Entonces, tenemos que:

$$\mu = \frac{\phi_0}{1 - \phi_1 - \dots - \phi_p}$$

$$\gamma_0 = \phi_1 \gamma_1 + \dots + \phi_p \gamma_p + \sigma^2$$

$$\gamma_k = \phi_k \gamma_{k-1} + \dots + \phi_p \gamma_{k-p}$$

## Modelos ARMA (cont.):

- Más generalmente, un modelo ARMA( $p, q$ ):

$$y_t = \phi_0 + \sum_{i=1}^p \phi_i y_{t-i} + \sum_{j=0}^q \theta_j \epsilon_{t-j}$$

es estable/estacionario si todas las raíces características del polinomio  $(1 - \phi_1 L - \dots - \phi_p L^p)$  están fuera del círculo unidad

- Además, un modelo ARMA( $p, q$ ) estable se puede expresar como un modelo MA( $\infty$ ):

$$\begin{aligned} y_t &= \frac{\phi_0}{1 - \phi_1 L - \dots - \phi_p L^p} + \frac{1 + \theta_1 L + \dots + \theta_q L^q}{1 - \phi_1 L - \dots - \phi_p L^p} \epsilon_t \\ &= \psi_0 + \psi(L) \epsilon_t \end{aligned}$$


donde  $\psi_0 = \frac{\phi_0}{1 - \phi_1 L - \dots - \phi_p L^p}$  y  $\psi(L) = \frac{1 + \theta_1 L + \dots + \theta_q L^q}{1 - \phi_1 L - \dots - \phi_p L^p}$

## Modelos ARMA (cont.):

- Si un modelo  $AR(p)$  es estable, entonces podemos expresarlo como un  $MA(\infty)$
- Si un modelo  $MA(q)$  es *invertible*, entonces podemos expresarlo como un  $AR(\infty)$
- **Definición: Invertibilidad de  $MA(q)$ .** Un modelo  $MA(q)$  se puede expresar como  $y_t - \phi_0 = (1 + \theta_1 L + \theta_2 L^2 + \dots + \theta_q L^q) \epsilon_t$ . Si el  $MA(q)$  se puede expresar como un modelo  $AR(\infty)$  utilizando la inversa de  $(1 + \theta_1 L + \theta_2 L^2 + \dots + \theta_q L^q)$ , entonces se dice que  $MA(q)$  es invertible.
- Condición suficiente para la invertibilidad: Que todas las raíces del polinomio  $(1 + \theta_1 z + \theta_2 z^2 + \dots + \theta_q z^q) = 0$  estén fuera del círculo unidad

## Tendencias:

- Consideramos la serie siguiente (PIB de España, 1950-2000):



## Tendencias (cont.):

- Se dice que esta serie tiene una *tendencia* (“trend”), porque crece durante toda la muestra
- Problema de regresión/correlación espúrea: regresiones/correlaciones sugieren una relación entre variables con tendencias aunque no hay ninguna relación
- Dos soluciones comunes a este problema son:
  - 1) tratar la serie como si tuviera una tendencia determinística (“deterministic trend”, “trend stationarity”)
  - 2) tratar la serie como si tuviera una tendencia estocástica (“stochastic trend”, “difference stationarity”)

## Tendencias (cont.):

- Dicho de otra manera, dos representaciones comunes de series económicas con tendencias son:

→ 1) Modelos con tendencia determinística:  $y_t = \phi_0 + \delta \cdot t + e_t$


→ 2) Modelos con tendencia estocástica:  $y_t = \phi_0 + \phi_1 y_{t-1} + e_t$

donde  $t$  es el tiempo,  $e_t$  es una componente estacionaria, y donde  $|\phi_1| \geq 1$

- *Nota:*  $e_t$  puede tener una estructura ARMA( $p, q$ ), por ejemplo,  $e_t = \epsilon_t + \theta_1 \epsilon_{t-1}$  (MA(1))


## Tendencias (cont.):

- ¿Cómo reconocemos las series con tendencia?
- Por ejemplo, ¿tiene esta serie una tendencia?:



## Tendencias (cont.):

- ¿Y esta?:



## Tendencias (cont.):

- “Trend stationarity” (TS) denota la propiedad de que la serie  $\{y_t - \text{tendencia determinística}\}$  es estacionaria (recuerda:  $\{e_t\}$  es estacionaria e igual a  $\{y_t - \text{tendencia determinística}\}$ )
- También se dice que  $\bar{y}_t = y_t - \text{tendencia determinística}$  es “de-trended”
- “Difference stationarity” denota la propiedad de que la serie  $\Delta^d y_t$  es estacionaria
- *Nota:* se pueden combinar las dos propiedades. Por ejemplo, puede ser que  $\{\Delta y_t\}$  se caracterice por una tendencia determinística
- ¿Es el problema de no-estacionariedad grave? Si, suele dar lugar a *regresiones espúreas*

## Tendencias (cont.):

- Intuitivamente, una regresión es espúrea si las pruebas estadísticas sugieren que hay una relación entre las variables cuando no la hay
- Supongamos que estamos considerando estimar la regresión

$$y_t = \beta_0 + \beta_1 x_t + \epsilon_t \quad (1)$$

donde  $\{y_t\}$  y  $\{x_t\}$  son series con tendencias

- ¿Cuál es la probabilidad de una regresión espúrea?  
→ Muy alta!

## Tendencias (cont.):

- *Ejemplo.* Paseos aleatorios independientes (series que “casi” tienen tendencia):

$$\rightarrow y_t = y_{t-1} + \epsilon_{y,t}, \quad \epsilon_{y,t} \sim WN(0, \sigma_y^2)$$

$$\rightarrow x_t = x_{t-1} + \epsilon_{x,t}, \quad \epsilon_{x,t} \sim WN(0, \sigma_x^2)$$

→  $\epsilon_{y,t}$  y  $\epsilon_{x,t}$  independientes

→  $y_t$  y  $x_t$  independientes

- ¿Cuál es la relación empírica entre  $y_t$  y  $x_t$ ? Granger y Newbold (1974) rechazaban la hipótesis de  $\beta_1 = 0$  (con un nivel de significación del 5%) en (1) para el 75% de las muestras simuladas

## Tendencias (cont.):

- Terminología: Una serie  $\{y_t\}$  es *integrada* (“integrated”) de orden  $d$  si  $\Delta^d y_t$  es una serie estacionaria. También se dice que  $d$  es el *orden de integración* (“order of integration”)
- Notación:  $y_t \sim I(d)$  y  $\text{ARIMA}(p, d, q)$ , donde  $d \geq 0$
- Si  $d$  no es un número entero, por ejemplo, si  $d = 0.6$  o si  $d = 2.6$ , diremos que el orden  $d$  es fraccional (“fractional integration”)
- *Nota:* En este curso no vamos a ver integración fraccional, siempre vamos a tratar las series como integradas de orden entero, es decir, de orden  $0, 1, 2, \dots$

## Tendencias (cont.):

- Ejemplos:

→ Si  $y_t$  no es estacionaria, pero  $\Delta y_t$  lo es, entonces denotamos  $y_t \sim I(1)$

→ Si ni  $y_t$ , ni  $\Delta y_t$  son estacionarias, pero  $\Delta^2 y_t$  lo es, entonces denotamos  $y_t \sim I(2)$

⋮

etc.

→ Si  $y_t$  ya es estacionaria, entonces denotamos  $y_t \sim I(0)$

## Tendencias (cont.):

- Cómo encontramos el orden de integración adecuado?
- Para apoyar o rechazar una hipótesis de orden  $d = 1$ , por ejemplo, podemos utilizar varios tipos de información:
  - (a) Inspección visual de gráficos
  - (b) Propiedades y tests estadísticos
  - (c) Sentido común
  - (d) Teoría
- *Nota:* Hay casos en los que los investigadores no están de acuerdo. Por ejemplo, hay casos en que no están de acuerdo si  $p_t \sim I(1)$  o si  $p_t \sim I(2)$ , donde  $p_t$  denota un índice de precios en logaritmos

## Prueba de Dickey-Fuller:

- Consideramos el modelo

$$y_t = \phi_1 y_{t-1} + \epsilon_t, \quad \epsilon_t \sim WN(0, \sigma^2) \quad (2)$$

- $|\phi_1| < 1$ :
  - $\{y_t\}$  estacionario
  - prueba de la  $t$  es válida
- $\phi_1 = 1$ :
  - $\{y_t\}$  no es estacionario
  - $\{y_t\}$  prueba de la  $t$  no es válida

## Prueba de Dickey-Fuller (cont.):

- Dickey y Fuller (1979) mostraron que, aunque la prueba de la  $t$  no es válida en (2) cuando  $\phi_1 = 1$ , la prueba de la  $t$  es válida para la especificación

$$\Delta y_t = \phi_0 + \pi y_{t-1} + \epsilon_t \quad (3)$$

cuando la hipótesis nula es  $\phi_1 = 1$  y donde  $\pi = \phi_1 - 1$

- Esta propiedad la utilizaron Dickey y Fuller (1979) para desarrollar una prueba de estacionalidad
- La prueba de “Dickey-Fuller” es una prueba de raíz unitaria (“unit root”), y para determinar los valores críticos para la hipótesis nula de  $\phi_1 = 1$  se necesita el método de Monte Carlo (simulación)

## Prueba de Dickey-Fuller (cont.):

- La prueba de Dickey-Fuller:
  - Estima  $\Delta y_t = \phi_0 + \pi y_{t-1} + \epsilon_t$  con MCO
  - $H_0: \pi = 0$
  - $H_1: \pi < 0$
- Compara el estadístico con el valor de la tabla de Dickey y Fuller (1979) o, mejor, con la tabla de MacKinnon (1996)
- *Nota:* EViews nos da los valores críticos de MacKinnon (1996) automáticamente

## Prueba de Dickey-Fuller (cont.):

- Normalmente, las variables requieren una representación  $AR(p)$  y no sólo  $AR(1)$
- La prueba de Dickey-Fuller aumentada:

→ Con MCO, estima

$$\Delta y_t = \phi_0 + \pi_0 y_{t-1} + \pi_1 \Delta y_{t-1} + \cdots + \pi_p \Delta y_{t-p} + \epsilon_t \quad (4)$$

→  $H_0: \pi_0 = 0$

→  $H_1: \pi_0 < 0$

- Compara el estadístico con el valor de la tabla de Dickey y Fuller (1979) o, mejor, con la tabla de MacKinnon (1996)
- *Nota:* EViews nos da los valores críticos de MacKinnon (1996) automáticamente

## Prueba de Dickey-Fuller (cont.):

- Problema práctico: elegir  $p$
- Soluciones posibles:
  - Incluir retardos de  $\Delta y_t$  hasta que el error sea ruido blanco
  - Incluir retardos de  $\Delta y_t$  significativos
  - Utilizar AIC, SBC, etc. (“information criteria”), para elegir  $p$
- Sin embargo, la prueba de Dickey-Fuller es frágil → siempre hay que utilizar información adicional (inspección visual de la serie, sentido común, historia, teoría) antes de aceptar o rechazar lo que sugiere la prueba de Dickey-Fuller

## Prueba de Dickey-Fuller (cont.):

- Tendencia lineal vs. tendencia estocástica: la prueba de Dickey-Fuller nos permite incluir un término de tendencia lineal  $\delta \cdot t$
- Es decir, contrastar  $\pi_0 = 1$  con la especificación

$$\Delta y_t = \phi_0 + \pi_0 y_{t-1} + \delta t + \pi_1 \Delta y_{t-1} + \dots + \pi_p \Delta y_{t-p} + \epsilon_t \quad (5)$$

- Problema: si hay variables innecesarias en (5), es más difícil rechazar la hipótesis nula de  $\pi_0 = 0$  (raíz unitaria) cuando en realidad  $\pi_0 < 0$
- Una solución: hacer tres pruebas

- 1. Sin la constante  $\phi_0$  y sin el término  $\delta t$
- 2. Con la constante  $\phi_0$  pero sin el término  $\delta t$
- 3. Con la constante  $\phi_0$  y el término  $\delta t$

## Descomposiciones:

- La descomposición de Beveridge y Nelson (1981) empieza con un modelo  $ARIMA(p, 1, q)$  de una serie  $\{y_t\}$
- Es decir, se supone que  $y_t \sim I(1)$ , y nosotros vamos a estudiar solamente el caso  $p = 0$
- En este caso un modelo  $ARIMA(0, 1, q)$  de  $\{y_t\}$  es igual a

$$\Delta y_t = \phi_0 + e_t, \quad (6)$$

donde  $e_t = MA(q)$ , es decir,  $e_t = \sum_{j=0}^q \theta_j \epsilon_{t-j}$  con  $\theta_0 = 1$

- El modelo (6) también se puede representar como un paseo aleatorio

$$y_t = \phi_0 + y_{t-1} + e_t,$$

es decir, como un  $ARMA(1, q)$  no-estacionario

## Descomposiciones (cont.):

- Para obtener la descomposición Beveridge-Nelson, primero hay que calcular la predicción condicional  $K > 0$  periodos hacia el futuro
- Tenemos que

$$y_{t+K} = \phi_0 K + y_t + \sum_{k=1}^K e_{t+k}$$

$$E_t(y_{t+K}) = \phi_0 K + y_t + E_t\left(\sum_{k=1}^K e_{t+k}\right)$$

donde  $E_t(\cdot)$  es la esperanza condicional  $E(\cdot | y_t, \epsilon_t, \epsilon_{t-1}, \dots)$

- El término  $\phi_0 K$  es la parte determinística, y la tendencia estocástica se define como

$$\lim_{K \rightarrow \infty} [E_t(y_{t+K}) - \phi_0 K]$$

## Descomposiciones (cont.):

- *Ejemplo.* Un modelo ARIMA(0,1,1) se puede escribir como:

$$y_t = \phi_0 + y_{t-1} + \epsilon_t + \theta_1 \epsilon_{t-1}$$

y nos da

$$y_{t+K} = \phi_0 K + y_t + \sum_{k=1}^K \epsilon_{t+k} + \theta_1 \sum_{k=1}^K \epsilon_{t+k-1}$$

$$E_t(y_{t+K}) = \phi_0 K + y_t + \theta_1 \epsilon_t$$

$$\lim_{K \rightarrow \infty} [E_t(y_{t+K}) - \phi_0 K] = y_t + \theta_1 \epsilon_t$$

- Si  $y_t = 10$ ,  $\theta_1 = 0,1$  y  $\epsilon_t = 1$ , entonces

$$\lim_{K \rightarrow \infty} E_t(y_{t+K}) - \phi_0 K = 10,1$$

## Descomposiciones (cont.):

- La descomposición de Hodrick y Prescott (1997) consiste en igualar los valores  $\{y_t\}$  de una serie con tendencia a dos componentes  $\mu_t$  y  $e_t$ :

$$y_t = \mu_t + e_t$$

- Intuitivamente  $\mu_t$  es una tendencia, y  $e_t = y_t - \mu_t$  es una componente estacionaria con  $E(e_t) = 0$  para todo  $t$
- El método de Hodrick y Prescott consiste en estimar una serie  $\mu_1, \dots, \mu_T$  tal que las diferencias  $\mu_{t+1} - \mu_t$  oscilan “suavemente”

## Descomposiciones (cont.):

- Más precisamente, el método de Hodrick-Prescott consiste en:
  1. Elegir un valor  $\lambda$  del “coste” de incorporar fluctuaciones en la serie  $\mu_1, \dots, \mu_T$
  2. Minimizar

$$\frac{1}{T} \sum_{t=1}^T (y_t - \mu_t)^2 + \frac{\lambda}{T} \sum_{t=2}^{T-1} [(\mu_{t+1} - \mu_t) - (\mu_t - \mu_{t-1})]^2 \quad (7)$$

- $\lambda = 0$ : no hay coste de incorporar fluctuaciones en la serie  $\mu_1, \dots, \mu_T$ , y el mínimo de (7) se obtiene cuando  $y_t = \mu_t$
- $\lambda \rightarrow \infty$ : coste alto de incorporar fluctuaciones en la serie  $\mu_1, \dots, \mu_T$ , y el mínimo de (7) se obtiene cuando  $\mu_{t+1} - \mu_t = \mu_t - \mu_{t-1}$ . Es decir, cuando la diferencia  $\mu_t - \mu_{t-1}$  es constante. Cuanto más grande es  $\lambda$ , más suave es el cambio  $\mu_t - \mu_{t-1}$

## Referencias:

- Beveridge, S. and C. Nelson (1981). A New Approach to Decomposition of Economic Time Series into Permanent and Transitory Components with Particular Attention to Measurement of the Business Cycles. *Journal of Monetary Economics* 7, 151–174.
- Dickey, D. and W. Fuller (1979). Distribution of the estimators for autoregressive time series with a unit root. *Journal of the American Statistical Association* 74, 426–431.
- Granger, C. W. and P. Newbold (1974). Spurious Regressions in Econometrics. *Journal of Econometrics* 2, 111–120.
- Hodrick, R. J. and E. C. Prescott (1997). Postwar U.S. Business Cycles: An Empirical Investigation. *Journal of Money, Credit and Banking* 29, 1–16.
- MacKinnon, J. G. (1996). Numerical Distribution Functions for Unit Root and Cointegration Tests. *Journal of Applied Econometrics* 11, 601–618.