


## Series de Tiempo

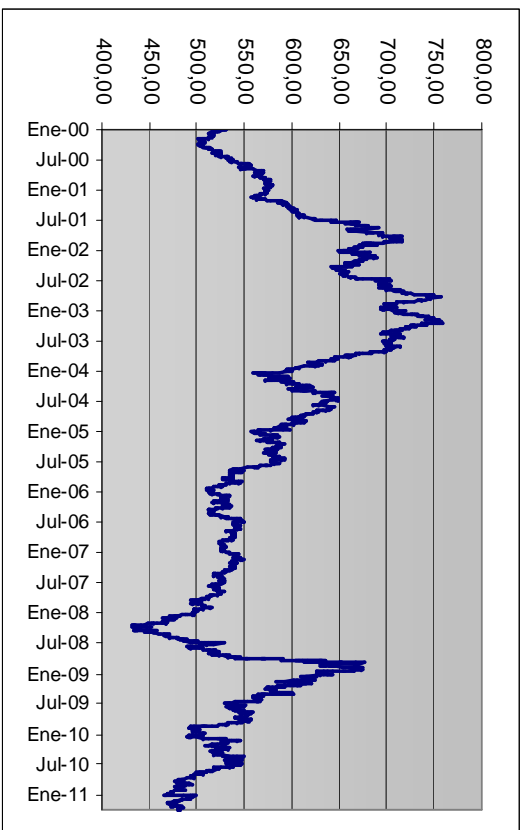
2011

J. Miguel Cruz


## Historia reciente del IPSA



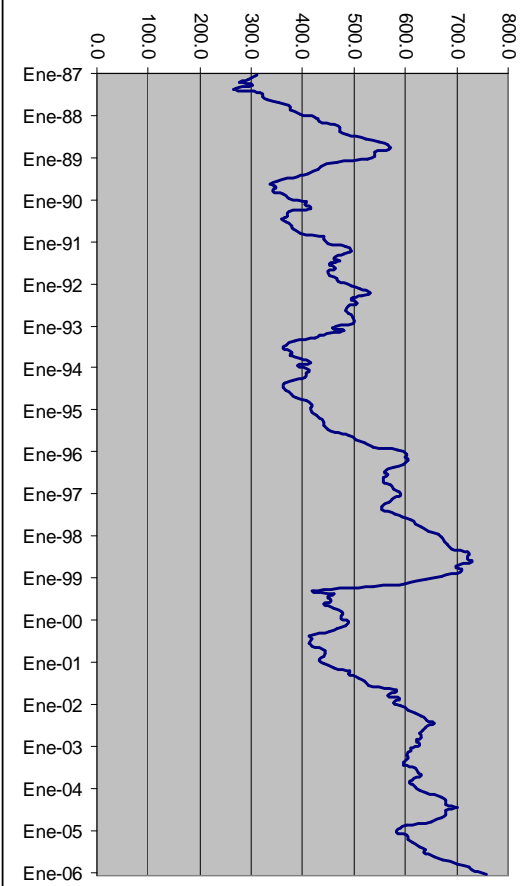
## Diez años de historia del dólar (Dólar Observado)




## Precio del Cobre




## Precio Harina de Pescado



## Precio del Petróleo



## Precio de la Celulosa



## Series de Tiempo

- Variables  $\{y_t\}$
- Observamos  $\{y_1 \dots y_T\}$
- Por ejemplo,  $y_t = \varepsilon_t + \mu$ ,
- O bien,  $y_t = \beta t + \varepsilon_t$
- Media o varianza pueden ser función del tiempo
- $f_{y_t}(y_t)$  función de densidad incondicional

## Necesidad de simplificar

- $E(y_1) \dots E(y_T)$  medias
- $V(y_1) \dots V(y_T)$  varianzas
- Y  $T(T-1)/2$  covarianzas  $\sigma_{ij} = \text{Cov}(y_i, y_j)$
- Tenemos una sola realización para inferir parámetros de una distribución conjunta (procesos ergódicos)

## Procesos estacionarios

- Proceso se encuentra en algún estado de equilibrio estático
- Proceso es estacionario de manera estricta si sus propiedades no cambian al modificar la fecha de origen
- Es decir la distribución de probabilidad conjunta para un conjunto de fechas  $t_1, t_2, \dots, t_m$  es la misma que la distribución para las fechas  $t_1+k, t_2+k, \dots, t_m+k$ , con  $k$  desplazamiento arbitrario.

## Implicancias de procesos estacionarios

- $E(y_1)=E(y_2)=E(y_T)= E(y_t)=\mu$
- $V(y_1)=V(y_2)=V(y_T)= V(y_t)=\sigma^2$
- $Cov(y_1,y_{1+k})=Cov(y_2,y_{2+k})=Cov(y_{T-k},y_T)= Cov(y_t,y_{t-k})$
- Podemos definir la autocovarianza  $\gamma_k$  y la autocorrelación  $\rho_k$  como

$$\gamma_k = Cov(y_t, y_{t-k}) = E[(y_t - \mu)(y_{t-k} - \mu)]$$

$$\rho_k = \frac{Cov(y_t, y_{t-k})}{\sqrt{V(y_t) \cdot V(y_{t-k})}} = \frac{\gamma_k}{\gamma_0}$$

## Propiedad Básica: Descomposición de Wold

- Cualquier serie estacionaria sin tendencia puede escribirse como una combinación lineal de variables aleatorias independientes
- Es decir,

$$y_t - \mu = a_t + \psi_1 \cdot a_{t-1} + \psi_2 \cdot a_{t-2} + \dots = \sum_{j=0}^{\infty} \psi_j \cdot a_{t-j}$$

- Con  $E(a_t)=0$ ,  $V(a_t)=\sigma^2$ , y  $E(a_t, a_{t-k})=0$ , para todo  $k \neq 0$

## Se puede mostrar que

$$\gamma_0 = \sigma^2 \sum_{j=0}^{\infty} \psi_j^2$$

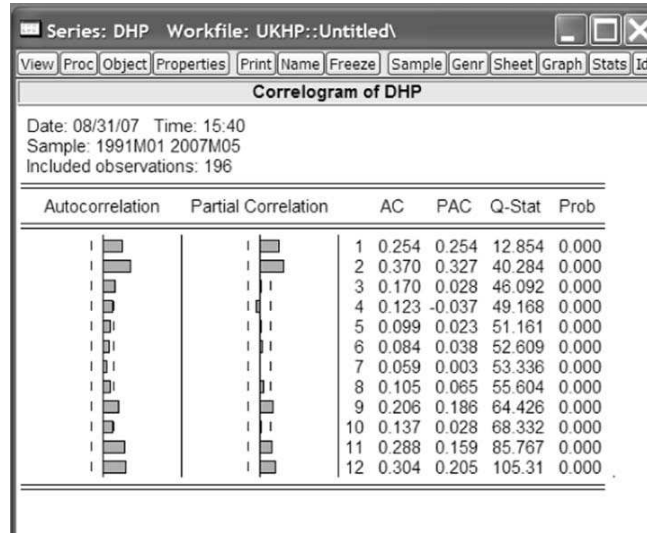
$$\gamma_k = \sigma^2 \sum_{j=0}^{\infty} \psi_j \cdot \psi_{j+k}$$

$$\rho_k = \frac{\sum_{j=0}^{\infty} \psi_j \cdot \psi_{j+k}}{\sum_{j=0}^{\infty} \psi_j^2}$$

## Test de las ACF

- Se propone que  $\rho_1 = \rho_2 = \dots = \rho_m = 0$
- Estadístico de Ljung & Box  $Q(m)$  chi-cuadrado de  $m$  grados de libertad (a veces  $m = \text{Ln}(T)$ )
- Si algún  $Q(m)$  es suficientemente grande, se rechaza la hipótesis

## Ejemplo de Output de Computador



## Un caso particular: AR(1)

- Supongamos que  $\mu=0$  y que

$$y_t = \phi \cdot y_{t-1} + a_t$$

- Usando el operador L (Lag)

$$Ly_t \equiv y_{t-1}$$

- AR(1) se escribe,

$$(1 - \phi L)y_t = a_t$$



## AR(1) se puede escribir como un MA( $\infty$ )

- Una forma de verlo es que

$$y_t = (1 - \phi L)^{-1} a_t = (1 + \phi L + \phi^2 L^2 + \dots) a_t$$

$$= a_t + \phi a_{t-1} + \phi^2 a_{t-2} + \dots \text{ con } |\phi| < 1$$

- Esto nos sirve para encontrar la autocovarianza  $\gamma_k$  y la autocorrelación  $\rho_k$

$$\gamma_k = \phi \cdot \gamma_{k-1} \quad k > 0$$

$$\rho_k = \phi^k$$

## AR(2)

- Caso general

$$y_t = \phi_0 + \phi_1 \cdot y_{t-1} + \phi_2 \cdot y_{t-2} + a_t$$

- Media incondicional

$$E(y_t) = \mu = \frac{\phi_0}{1 - \phi_1 - \phi_2}$$

- Se puede reescribir como:

$$y_t - \mu = \phi_1 \cdot (y_{t-1} - \mu) + \phi_2 \cdot (y_{t-2} - \mu) + a_t$$

## ACF de AR(2)

- Multiplicando por  $(y_{t-k}-\mu)$  y como  $E[(y_{t-k}-\mu)a_t]=0$  para  $k>0$ , entonces

$$\gamma_k = \phi_1 \cdot \gamma_{k-1} + \phi_2 \cdot \gamma_{k-2} \quad k > 0$$

- Dividiendo por  $\gamma_0$ , entonces

$$\rho_k = \phi_1 \cdot \rho_{k-1} + \phi_2 \cdot \rho_{k-2} \quad k > 0$$

- Solución de esta ecuación es

$$\rho_0 = 1$$

$$\rho_1 = \frac{\phi_1}{1-\phi_2}$$

$$\rho_k = \phi_1 \cdot \rho_{k-1} + \phi_2 \cdot \rho_{k-2} \quad k \geq 2$$

## Polinomio Característico

- Proceso en  $\rho$  se puede escribir como

$$(1 - \phi_1 \cdot L - \phi_2 \cdot L^2) \rho_k = 0$$

- Polinomio asociado

$$1 - \phi_1 \cdot x - \phi_2 \cdot x^2 = 0$$

- Soluciones

$$x = \frac{\phi_1 \pm \sqrt{\phi_1^2 + 4\phi_2}}{-2\phi_2} = w_{1,2}$$

## AR(2) y ciclos

- Si  $w_1$  y  $w_2$  son las raíces reales del polinomio, entonces

$$(1 - \phi_1 \cdot L - \phi_2 \cdot L^2) = (1 - w_1 L)(1 - w_2 L)$$

- Si  $\phi_1^2 + 4\phi_2 < 0$  entonces ACF es una combinación de senos y cosenos, con raíces complejas  $a+bi$  y con ciclos de largo promedio  $k$ :

$$k = \frac{2\pi}{\cos^{-1}(a/\sqrt{a^2 + b^2})}$$

## AR(p)

- AR(p):

$$y_t = \phi_0 + \phi_1 \cdot y_{t-1} + \phi_2 \cdot y_{t-2} + \dots + \phi_p \cdot y_{t-p} + a_t$$

- Media

$$E(y_t) = \mu = \frac{\phi_0}{1 - \phi_1 - \phi_2 - \dots - \phi_p}$$

- ACF

$$(1 - \phi_1 \cdot L - \phi_2 \cdot L^2 - \dots - \phi_p \cdot L^p) \rho_k = 0 \quad k > 0$$

## Cómo reconocer un modelo AR?

- PACF: Se estiman las siguientes regresiones lineales

$$y_t = \phi_{0,1} + \phi_{1,1} \cdot y_{t-1} + e_{1,t}$$

$$y_t = \phi_{0,2} + \phi_{1,2} \cdot y_{t-1} + \phi_{2,2} \cdot y_{t-2} + e_{2,t}$$

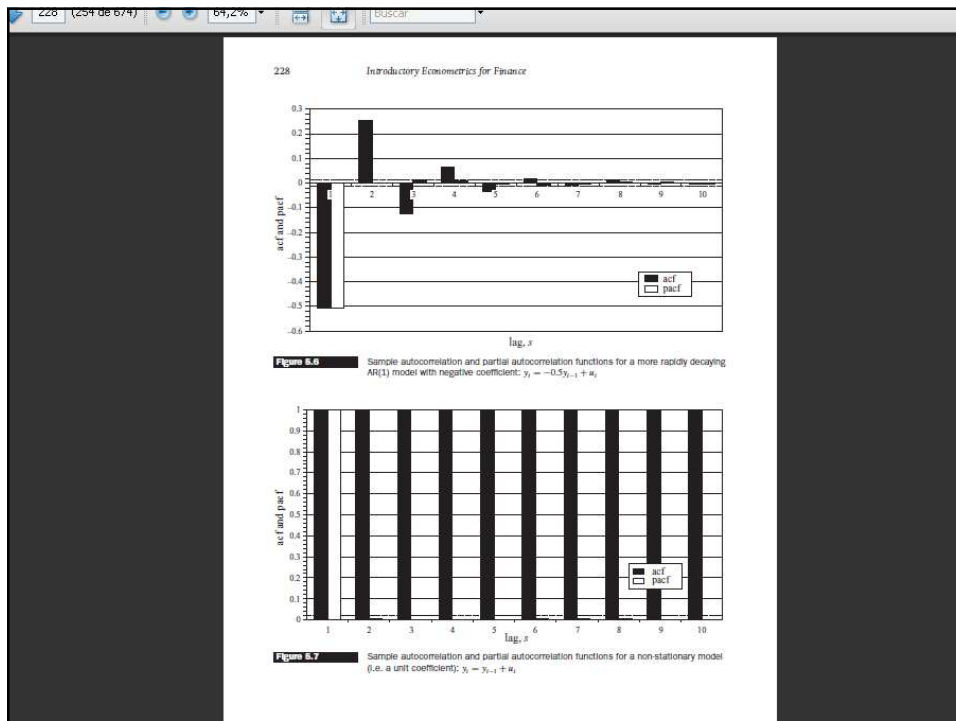
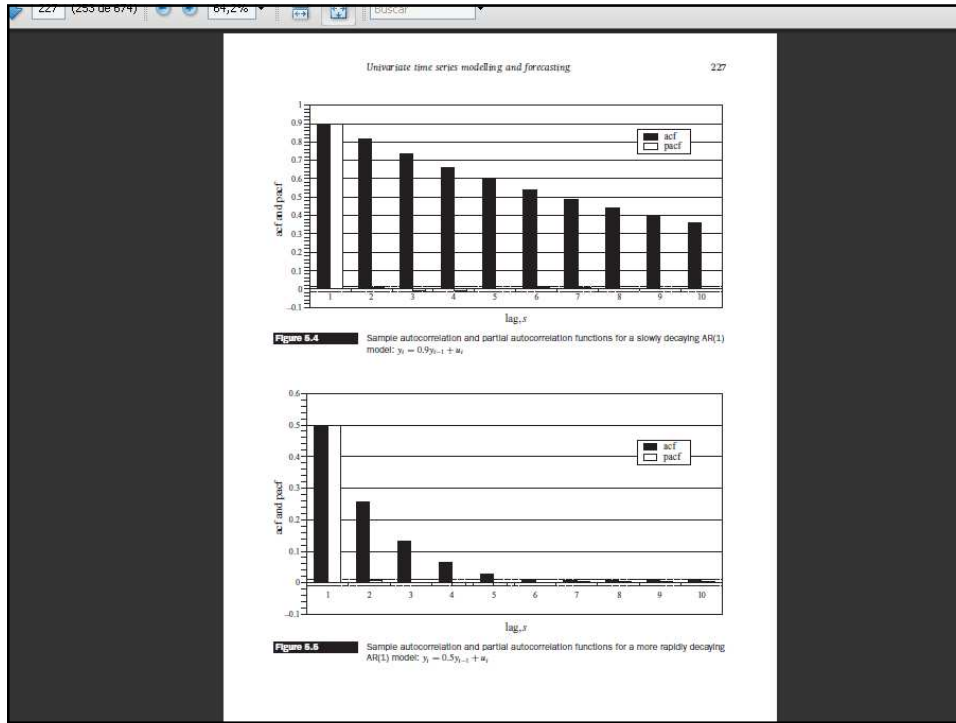
$$y_t = \phi_{0,3} + \phi_{1,3} \cdot y_{t-1} + \phi_{2,3} \cdot y_{t-2} + \phi_{3,3} \cdot y_{t-3} + e_{3,t}$$

⋮

- $\Phi_{22}$  es la contribución marginal de  $y_{t-2}$  a  $y_t$ . Luego para un modelo AR(p), los términos  $\Phi_{jj}$  deben ser cercanos a cero para  $j > p$ .

## PACF Muestrales

- $\Phi_{pp}$  converge a  $\Phi_p$  cuando T tiende a infinito
- $\Phi_{ll}$  converge a 0 para  $l > p$
- La varianza asintótica de  $\Phi_{ll}$  es  $1/T$  para  $l > p$
- $\pm 2/\sqrt{T}$  corresponde a 2 desviaciones estándares
- Akaike Information Criterion AIC(k)...se escoge el k que tenga mínimo AIC



## Generalización

- AR(p)  $\phi(L)y_t = a_t$   
 $(1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p)y_t = a_t$
- Estacionario si  $(1 - g_1 L) \cdot (1 - g_2 L) \cdot \dots \cdot (1 - g_p L) = 0$
- Son tales que  $|g_i| < 1$
- Lo que se puede representar  $y_t = \psi(L)a_t$
- Donde los coeficientes se deducen de  $\phi(L) \cdot \psi(L) = 1$

## Proceso MA(1)

- Procesos basado sólo en innovaciones aleatorias

$$y_t = a_t + \theta \cdot a_{t-1}$$

$$y_t = (1 - \theta L)a_t$$

- Podemos encontrar la autocovarianza  $\gamma_k$  y la autocorrelación  $\rho_k$  ?

## Estimación de procesos MA

- Estimar el orden  $q$  MA( $q$ ), por estudio de las ACF
- Máxima verosimilitud

## Combinaciones ARMA( $p,q$ )

- Ejemplo ARMA(1,1)

$$y_t - \phi \cdot y_{t-1} = a_t + \theta \cdot a_{t-1}$$

- Representación MA?
- Representación AR?

## Estimaciones ARMA(1,1)

- **Cómo estimamos?**
  - ACF de un ARMA(1,1) se comporta como AR(1), pero a partir del rezago 2.
  - PACF de un ARMA(1,1) se comporta como un MA(1), pero a partir del rezago 2
- **ACF y PACF no son tan útiles**
- **Se requiere EACF (Extended Autocorrelation Function)**

## EACF

- **X** valor absoluto de EACF  $\geq 2/\sqrt{T}$
- **0** valor absoluto de EACF  $< 2/\sqrt{T}$
- **\* X o 0.**

		MA					
		0	1	2	3	4	5
AR	0	X	X	X	X	X	X
	1	X	0	0	0	0	0
	2	*	X	0	0	0	0
	3	*	*	X	0	0	0
	4	*	*	*	X	0	0
	5	*	*	*	*	X	0

The table is annotated with a vertical dashed line labeled 'q' at the top, pointing to the column index 1. A horizontal dashed line labeled 'p' on the left points to the row index 1.



## Estimación de procesos de tasas de Interés

Modelo de Vasicek

$$r_{t+\Delta t} = r_t + a \cdot (b - r_t) \cdot \Delta t + \sigma \cdot \sqrt{\Delta t} \cdot N(0,1)$$

$$r_{t+1} = r_t + a \cdot (b - r_t) + \varepsilon_t$$

Qué tipo de proceso es?

## Procesos no estacionarios

- No estacionario en varianza
- Hay que buscar una transformación tal que “estabilice” la varianza
- No estacionario en media...puede ser un proceso explosivo

## Procesos no estacionarios:

- Procesos de raíces unitarias
- Ejemplo:  $y_t = \beta_0 + \beta_1 t + \varepsilon_t$
- $\Rightarrow y_t - y_{t-1} = \beta_1 + \varepsilon_t - \varepsilon_{t-1}$
- Qué proceso es este?
  
- Si definimos  $w_t = y_t - y_{t-1} \Rightarrow (1-L)y_t = \Delta y_t$
- Entonces  $w_t$  es ahora qué proceso?

## Camino aleatorios

- Supongamos  $\mu = 0$  a  $a_t$  WN

$$y_t = \phi \cdot y_{t-1} + a_t$$

- Y además  $\phi = 1$

$$y_t = y_{t-1} + a_t$$

Camino aleatorio

$$y_t = y_{t-1} + \mu + a_t$$

Camino aleatorio con drift  
(driza)

## Propiedades del camino aleatorio

- Podemos recursivamente deducir que,

$$y_t = y_0 + t \cdot \mu + \sum_{i=0}^{t-1} a_{t-i}$$

- Por lo que  $E_0(y_t)$ ,  $\gamma_{0,t}=V_0(y_t)$  y  $\gamma_{k,t}=\text{Cov}(y_t, y_{t-k})$  se pueden ahora calcular. Verdad?
- RW (CA) es un proceso integrado, es decir la primera diferencia lleva a un proceso estacionario

$$\Delta y_t = \mu + a_t$$

## Test de Raíces Unitarias

- Dickey Fuller Test (Test t de  $\Phi_1-1$ )
- Alternativamente, DF Aumentado:
- Para AR(p), Se corre regresión

$$y_t = c_t + \beta \cdot y_{t-1} + \sum_{i=1}^{p-1} \phi_i \Delta y_{t-i} + e_t$$

- Con  $c_t$  una función determinística de t (por ejemplo, 0, constante, o bien  $w_0 + w_1 \cdot t$ ) y

$$\Delta y_j = y_j - y_{j-1}$$

- Se testea si  $\beta$  es significativamente distinto de 1

## ARIMA(p,d,q)

- Podría darse que el proceso sea necesario diferenciarlo  $d$  veces para llegar a un proceso estacionario,
- ... que puede a su vez ser un proceso ARMA(p,q)
- Esto se escribe:

$$\phi(L)\Delta^d y_t = \theta_0 + \theta(L)a_t$$

- Generalmente  $d=0,1$ , o bien a lo más 2.