

## Capítulo 5

# Procesos Integrados

Un proceso no estacionario puede no ser estable en la media, en la varianza o en las autocorrelaciones. Por ejemplo, las series 3, 5-13, 19, 29-31, 35-37, y 39 del Capítulo 0 no son estables en la media.

**Procesos integrados:** Procesos no estacionarios comunes son los procesos integrados, que se convierten en estacionarios simplemente tomando diferencias.

- Si  $(Y_t)$  no es estacionario pero la serie  $(Z_t)$  de las primeras diferencias

$$Z_t = \nabla Y_t = Y_t - Y_{t-1},$$

sí lo es, entonces  $(Y_t)$  es un proceso “integrado de orden uno”,  $I(1)$ .

- Si  $(\nabla Y_t)$  no es estacionario, pero la serie  $(Z_t)$  de las segundas diferencias

$$Z_t = \nabla^2 Y_t = Y_t - 2Y_{t-1} + Y_{t-2},$$

sí lo es, entonces  $(Y_t)$  es un proceso “integrado de orden dos”,  $I(2)$ .

- Un proceso es “integrado de orden  $d$ ”,  $I(d)$ ,  $d \geq 0$ , si al diferenciarlo  $d$  veces (y no menos) resulta un proceso estacionario.
- Un proceso estacionario es integrado de orden 0 y se denota por  $I(0)$ .

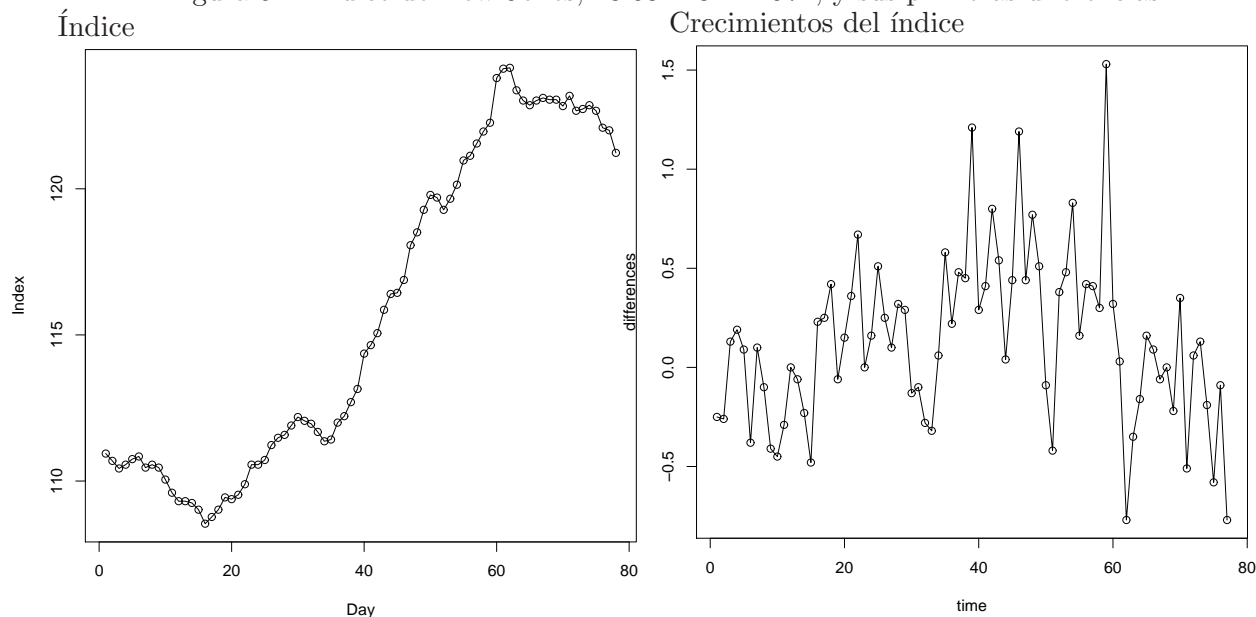
El término *integrado* indica que el proceso es suma de los elementos hasta  $t$  de un proceso estacionario. Si  $(Y_t)$  es integrado de orden  $d$ , llamando  $Z_t = \nabla^d Y_t$  al proceso estacionario, entonces  $(Y_t)$  es suma (integración) de  $(Z_t)$ . Por ejemplo, sea el proceso de primeras diferencias  $Z_t = \nabla Y_t = Y_t - Y_{t-1}$ .

Despejamos  $Y_t$  en función de los valores de  $Z_t$ :

$$\begin{aligned} Y_t &= \dots \\ &= \dots \\ &= \dots \end{aligned}$$

En la práctica se suelen considerar procesos integrados de orden  $d \leq 3$ .

Figura 5.1: Índice de Dow Jones, 28.08.–18.12.1972, y sus primeras diferencias



## 5.1. Procesos integrados de orden 1, $I(1)$

### 5.1.1. El paseo aleatorio con deriva

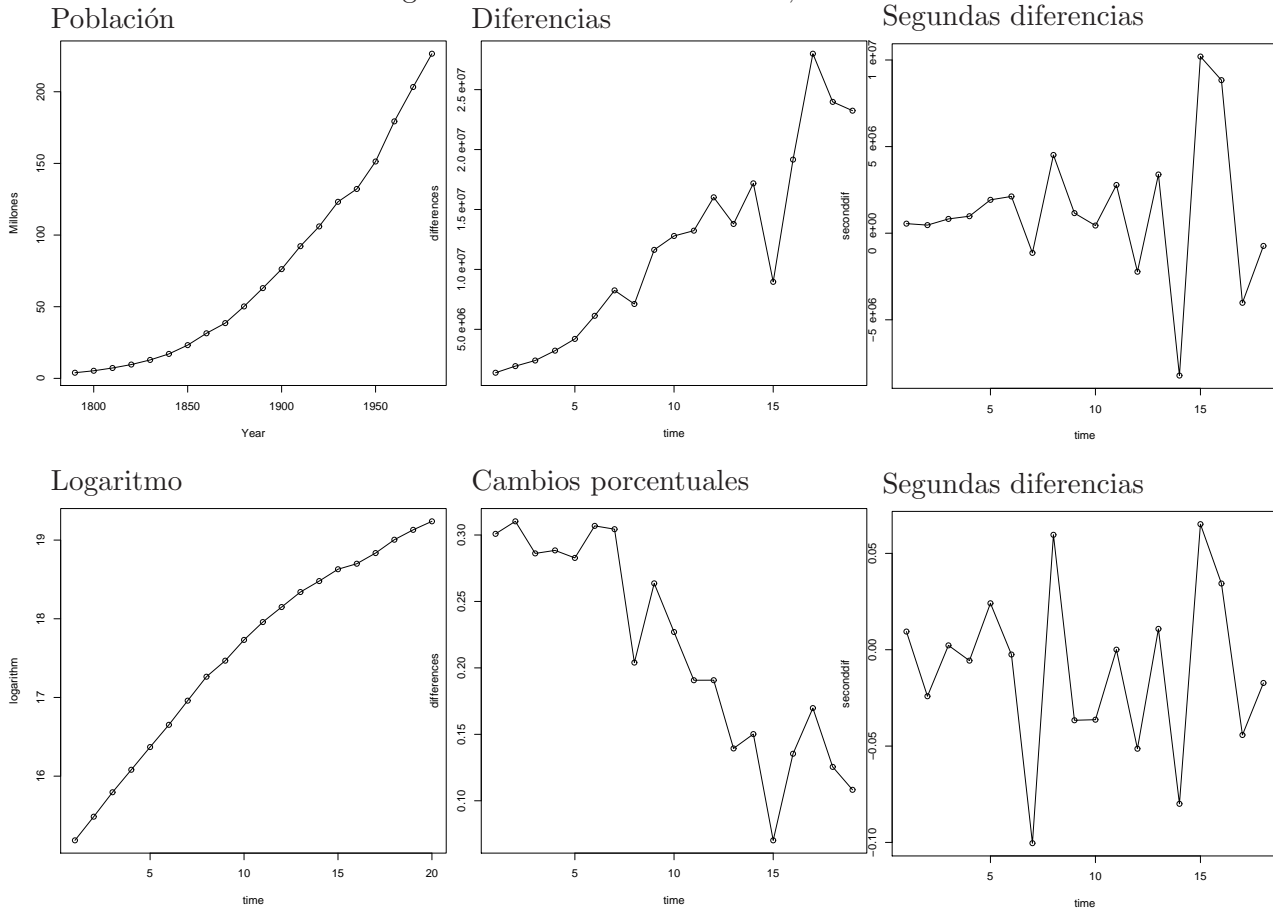
El proceso AR(1) dado por

$$Y_t = c + \phi Y_{t-1} + a_t$$

es estacionario si  $|\phi| < 1$  y explosivo si  $|\phi| > 1$ . Para  $\phi = 1$  es  $I(1)$ , ya que verifica

$$Y_t - Y_{t-1} = c + a_t.$$

Figura 5.2: Población de EE.UU, 1790–1900



**Paseo aleatorio con deriva  $c$ :** Es un proceso AR(1) con  $\phi = 1$ , es decir

$$Y_t = c + Y_{t-1} + a_t \Leftrightarrow \nabla Y_t = c + a_t$$

**Nota:**


- En un proceso estacionario o  $I(0)$ , la constante  $c$  regula la media constante. Restando la media podemos trabajar con un proceso sin constante.
- En un proceso  $I(1)$ , la constante  $c$  regula la tendencia. Se dice que el proceso tiene “deriva”  $c$ .

Figura 5.3: Procesos AR(1) con  $\phi \geq 1$

$\phi = 1,02$  y  $c = 0$

$\phi = 1$  y  $c = 0$

$\phi = 1$  y  $c = 0,5$



**Solución de la ecuación:** Calculamos la solución de la ecuación del paseo aleatorio de forma recursiva suponiendo  $Y_0 = 0$ ,

$$\begin{aligned} Y_1 &= \dots \\ Y_2 &= \dots \\ Y_3 &= \dots \\ &\vdots \\ Y_t &= \dots \end{aligned}$$

**Esperanza:**

$$E(Y_t) = \dots$$

**Varianza:**

$$Var(Y_t) = \dots$$

**Autocovarianzas:**

$$Cov(Y_t, Y_{t+h}) = \dots$$

$$Cov(Y_t, Y_{t-h}) = \dots$$

**Autocorrelaciones:**

$$\rho(Y_t, Y_{t+h}) = \dots$$

- ✓ El paseo aleatorio no es estable en media ni en varianza y las autocovarianzas no dependen solo del retardo;
- ✓ Para un  $t$  fijo, las autocorrelaciones decrecen con  $h$  de forma lineal.



Figura 5.4: *Fas* de procesos integrados

*Fas* del paseo aleatorio

random walk

*Fas* del índice de Dow Jones

dow.jones





*Fas* de los incrementos

differences

*Fas* de los incrementos

differences





*Fap* de los incrementos

differences

*Fap* de los incrementos

differences



### 5.1.2. El proceso de alisado exponencial simple o IMA(1,1)

**Modelo:** El IMA(1,1) es el caso límite del ARMA(1,1) cuando  $\phi_1 \rightarrow 1$ , es decir,

$$Y_t = c + Y_{t-1} + a_t - \theta_1 a_{t-1} \Leftrightarrow \nabla Y_t = c + (1 - \theta_1 B)a_t$$

Este modelo coincide con el paseo aleatorio si  $\theta_1 = 0$ . Es un modelo popular para la predicción.

**Solución:** Sustituyendo de forma recursiva, obtenemos

$$\begin{aligned} Y_t &= \dots \\ &= \dots \\ &= \dots \\ &= \dots \end{aligned}$$

Si suponemos que la serie comienza en  $Y_0 = a_0 = 0$ , entonces

$$Y_t = \dots$$

**Media:** Tomando esperanza, obtenemos

$$E(Y_t) = \dots$$

**Varianza:** Tomando varianza, se obtiene

$$Var(Y_t) = \dots$$

**Autocovarianzas:** Tomamos  $h > 0$ ,

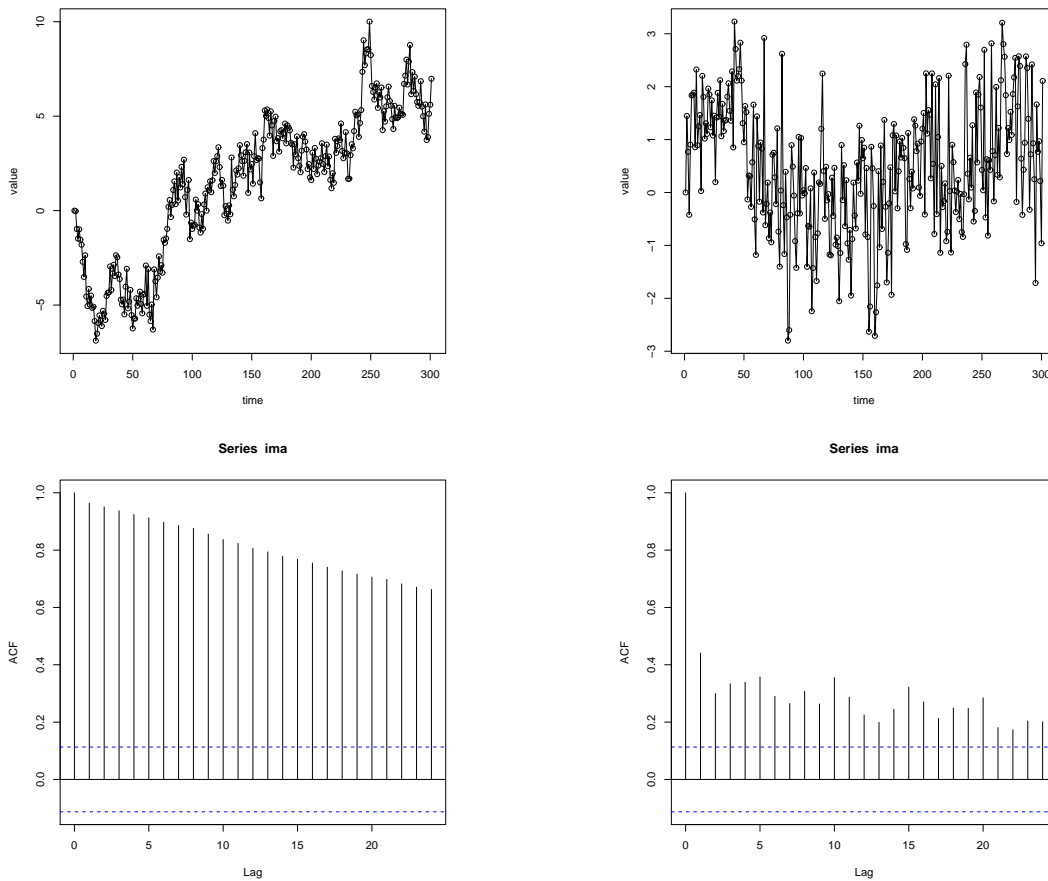
$$\begin{aligned} Cov(Y_t, Y_{t+h}) &= \dots \\ &= \dots \\ &= \dots \end{aligned}$$

**Autocorrelaciones:** Para  $h > 0$ , se tiene

$$\rho(Y_t, Y_{t+h}) = \dots$$

- Para  $t$  grande, si  $\theta_1 \approx 0$ , las autocorrelaciones se pueden aproximar por  $\rho(Y_t, Y_{t+h}) \cong (1 + h/t)^{-1/2}$ , como para el paseo aleatorio.

Figura 5.5: Series IMA(1,1) y sus correlogramas,  $\theta_1 = 0,4$  (izq.) y  $\theta_1 = 0,9$  (der.)



- Si  $\theta_1 \cong 1$ , las autocorrelaciones no tienen por qué ser grandes, y van decreciendo de forma lineal.

**Representación  $AR(\infty)$ :** Invertimos el proceso IMA(1,1) con  $c = 0$ , dado por

$$\nabla Y_t = (1 - \theta_1 B)a_t,$$

donde  $|\theta_1| < 1$ . ...



¿Cuánto suman los pesos de las observaciones pasadas?

...

✓ El valor de la serie en  $t$  es una media ponderada de los valores de la serie en los instantes anteriores, con pesos que decrecen al alejarse en el pasado.

✓ Si  $\theta_1 \cong 0$ , se tienen solo en cuenta las observaciones más recientes.

✓ Si  $\theta_1 \cong 1$ , se hace una media ponderada de muchos datos históricos.

## 5.2. Procesos integrados de orden 2, $I(2)$

Un modelo  $I(2)$  que aparece en muchas aplicaciones es el IMA(2,1) dado por la ecuación

$$\nabla^2 Y_t = (1 - \theta B)a_t \Leftrightarrow (1 - B)^2 Y_t = (1 - \theta B)a_t.$$

Consideremos un paseo aleatorio con deriva no constante, dado por la ecuación

$$\nabla Y_t = c_t + u_t, \tag{5.1}$$

donde  $u_t$  es un ruido blanco y  $c_t$  sigue el modelo

$$c_t = c_{t-1} + \epsilon_t,$$

siendo  $\epsilon_t$  otro ruido blanco independiente de  $u_t$ . Entonces al tomar otra diferencia en (5.1) obtenemos

$$\begin{aligned} \nabla^2 Y_t &= \dots \\ &= \dots \\ &= \dots \\ &= \epsilon_t + Z_t, \end{aligned}$$

donde  $Z_t = u_t - u_{t-1}$  es un MA(1) no invertible. Pero se verifica

Ruido blanco + MA(1) no invertible = MA(1) invertible.

Por tanto,  $\nabla^2 Y_t$  es una MA(1) invertible, y entonces  $Y_t$  es un IMA(2, 1).

✓ Los procesos integrados de orden 2 son generalizaciones de los  $I(1)$  con pendiente variable.

### 5.3. Procesos integrados ARIMA( $p, d, q$ )

**Modelo:** Un proceso ARIMA( $p, d, q$ ) (“autoregressive integrated moving average”) sigue la ecuación

...

donde

$p$  es el orden de la parte autorregresiva estacionaria;

$d$  es el número de raíces unitarias u orden de integración;

$q$  es el orden de la parte media móvil.

En función del operador retardo, el modelo es

$$\Phi_p(B)\nabla^d Y_t = c + \Theta_q(B)a_t$$

El paseo aleatorio es un ARIMA(..., ..., ..) y el alisado exponencial simple es un ARIMA(..., ..., ...).

✓ Estos procesos se caracterizan porque su *fas* decrece lentamente.

Efectivamente, tomemos un proceso no integrado ARMA( $p, q$ ) dado por

$$\Phi_p(B)Y_t = \Theta_q(B)a_t.$$

Sabemos que la *fas* es solución de la ecuación en diferencias

$$\Phi_p(B)\rho_h = 0.$$

La solución a esta ecuación es

$$\rho_h = \sum_{i=1}^p A_i G_i^h$$


donde  $G_1^{-1}, \dots, G_p^{-1}$  son las raíces de la ecuación característica  $\Phi_p(B) = 0$  y  $A_1, \dots, A_p$  son constantes. Supongamos que los  $G_i$  están todos dentro del

círculo unidad, pero uno de ellos,  $G_j$  está cerca de 1; es decir, el proceso es “casi” integrado. Tomamos  $G_j = 1 - \epsilon$ ,  $\epsilon > 0$  pequeño. Entonces, para  $h$  grande,

$$\rho_h = \sum_{i=1; i \neq j}^p A_i G_i^h + A_j G_j^h \cong A_j G_j^h = A_j (1 - \epsilon)^h,$$

y como  $\epsilon$  es pequeño, esto tiende a cero muy lentamente.

Figura 5.6: Serie ARIMA(1,1,1) con  $\phi_1 = 0,4$  y  $\theta_1 = 0,6$  (izq.) y su correlograma (der.)



## 5.4. Procesos integrados y tendencias

✓ Los procesos ARIMA incluyen muchos procesos no estacionarios que aparecen en la práctica.

✓ En particular, incluyen como casos límite a procesos con tendencia tanto determinista como estocástica.

Se verifica que

Tendencia polinómica + Proceso estacionario = Proceso integrado.

**Ejemplo 37** Consideremos el proceso con tendencia determinista lineal,

$$Y_t = b + ct + u_t, \quad u_t \text{ ruido blanco.}$$

Tomando la primera diferencia, obtenemos

$$\begin{aligned} \nabla Y_t &= \dots \\ &= \dots \end{aligned}$$

donde  $\nabla u_t$  es estacionario (es diferencia de procesos estacionarios) pero no es invertible. Por tanto,  $\nabla Y_t$  es integrado de orden 1,  $I(1)$ .

**Ejemplo 38** Consideremos el proceso con tendencia determinista polinómica

$$\begin{aligned} Y_t &= \mu_t + u_t \\ \mu_t &= \beta_0 + \beta_1 t + \dots + \beta_d t^d \end{aligned}$$

Diferenciando  $d$  veces obtenemos un proceso estacionario no invertible,

$$\nabla^d Y_t = d\beta_d + \nabla^d u_t,$$

donde  $\nabla^d u_t$  es un proceso estacionario al ser diferencia entre procesos estacionarios. Por tanto,  $Y_t$  es un proceso integrado de orden  $d$ ,  $I(d)$ .

**Ejemplo 39** Consideremos el proceso anterior con  $d = 2$ , es decir,

$$Y_t = \mu_t + u_t, \quad \mu_t = \beta_0 + \beta_1 t + \beta_2 t^2,$$

pero donde ahora  $u_t$  es un  $AR(1)$ , es decir,

$$(1 - \phi_1 B)u_t = a_t \Leftrightarrow u_t = (1 - \phi_1 B)^{-1} a_t.$$

Tomando diferencia de orden 2, obtenemos

$$\nabla^2 Y_t = \dots$$

donde

$$\begin{aligned} \nabla^2 u_t &= \dots \\ \Leftrightarrow (1 - \phi_1 B)\nabla^2 u_t &= \dots \end{aligned}$$

Es decir, el proceso  $\nabla^2 u_t$  es un  $ARMA(1, 2)$  no invertible. Entonces,  $\nabla^2 Y_t$  es un  $ARIMA(1, 1, 2)$ .

**Nota 13** Modelizamos unos datos con un proceso  $ARIMA$ . Entonces

- Si tenemos una serie con tendencia polinómica de orden  $d$  y la diferenciamos  $d$  veces, obtenemos componentes media móvil no invertibles.
- La serie diferenciada tendrá media distinta de 0, y esta media es función del coeficiente de orden mayor de la tendencia.

**Ejemplo 40** Consideremos el proceso con nivel estocástico pero pendiente determinista definido por

$$Y_t = \mu_t + u_t$$

donde el nivel en  $t$  se obtiene sumando una constante  $c$  (la pendiente) al nivel en  $t - 1$  de la forma

$$\mu_t = \mu_{t-1} + c + \epsilon_t,$$

y donde  $(u_t)$  y  $(\epsilon_t)$  son ruidos blancos independientes. Tomando primera diferencia, obtenemos

$$\nabla Y_t = \dots$$

donde

$$\nabla \mu_t = \dots \quad \Rightarrow \quad \nabla Y_t = \dots$$

Es decir,  $\nabla Y_t$  es suma de un ruido blanco y un MA(1) no invertible, que es un MA(1) invertible. Por tanto,  $Y_t$  es un IMA(1,1).

**Ejemplo 41** En la práctica es difícil encontrar unos datos en los que la tendencia siga exactamente una función concreta. Los procesos con tendencia estocástica son bastante más realistas. Consideremos el proceso definido por

$$\begin{aligned} Y_t &= \mu_t + u_t, \\ \mu_t &= \mu_{t-1} + \beta_t + \epsilon_t, \\ \beta_t &= \beta_{t-1} + \delta_t, \end{aligned}$$

donde  $(u_t)$ ,  $(\epsilon_t)$  y  $(\delta_t)$  son ruidos blancos independientes. En este proceso, la media crece de forma lineal, pero con pendiente variable.

Tomando una diferencia, obtenemos

$$\nabla Y_t = \dots$$

donde

$$\nabla \mu_t = \dots \quad \Rightarrow \quad \nabla Y_t = \dots$$

Tomando ahora una segunda diferencia, obtenemos

$$\nabla^2 Y_t = \dots$$

El término de la derecha es un MA(2) invertible, ya que es suma de un MA(2), un MA(1) y ruido blanco; por tanto,  $Y_t$  es un IMA(2,2).

✓ Si las varianzas de  $\epsilon_t$  y  $\delta_t$  son cero, obtenemos un modelo con tendencia determinista.