

Tema 03.01: Procesos estocásticos estacionarios con R

@umh1465: Análisis estadístico de series económicas

Xavi Barber

Centro de Investigación Operativa
Universidad Miguel Hernández de Elche

2018-03-08



- 1 Procesos estocásticos estacionarios
- 2 La media de una serie
- 3 El proceso ruido blanco
- 4 Random Walk
- 5 ACF y PACF con R

Valencia Bayesian Research group

Procesos estocásticos estacionarios

Valencia Bayesian Research group

Luego el fenómeno inflación mensual en un determinado país será una secuencia (posiblemente infinita) de variables aleatoria ordenadas en el tiempo

$$x(1), x(2), \dots, x(t), \dots, x(T)$$

A esta secuencia de variables aleatorias se le denomina **proceso estocástico**.

Una serie temporal es una realización finita de un proceso estocástico.

Proceso estocástico	$x(1), x(2), \dots, x(t), \dots, x(T)$
Serie temporal (observada)	x_1, x_2, \dots, x_t

Debemos tener claro y diferenciar entre:

- Proceso estocástico: la inflación mensual en España.
- Variable aleatoria: la inflación mensual en el mes t en España.
- La inflación observada en el mes t es la realización de esta variable aleatoria, pero otras realizaciones podrían ser posibles.

Valencia Bayesian Research group

Evolución de la ley probabilística de un proceso estocástico

La evolutividad podría referirse a distintos parámetros de la ley probabilística.

- En fenómenos económicos, los principales parámetros evolutivos son:
 - Media
 - Varianza (desviación típica).

Valencia Bayesian Research group

La media de una serie

Valencia Bayesian Research group

Evolución en la varianza

- En series financieras, la varianza condicional no es constante sino que depende del pasado.
- Esto requiere una modelización específica que no se cubrirá en este curso sino en una asignatura específica de econometría de series financieras.

Valencia Bayesian Research group

Series con tendencia

- Lineal

$$X_t = a + bt + W_t$$

- Exponencial

$$X_t = e^{a+bt} e^{W_t}$$

$$\log(X_t) = a + bt + W_t$$

Valencia Bayesian Research group

Series temporales con un claro límite superior en su evolución.

- Curva de Gompertz

$$\log(T_t) = a + br^t, 0 < r < 1$$


- Curva logística

$$T_t = \frac{1}{a + br^t}, 0 < r < 1$$

- Posibles ejemplos:

- Porcentaje de personas alfabetizadas en una sociedad desarrollada, porcentaje de casas con electricidad, etc.
- En otros casos no está claro que exista un límite superior: número de teléfonos o automóviles por cada mil habitantes.

Ejemplo de Curva de Gompertz



Tendencia estocástica

Para ver como funciona el proceso $y_t = y_{t-1} + w_t$

- Podemos realizar sustituciones recursivas. Si suponemos que existe un periodo inicial que denotamos por y_0 , la solución del sistema viene dada por

$$y_t = y_0 + \sum_i w_i$$

- Tomando expectativas obtenemos $E(y_t) = E(y_0)$. Es decir, se trata de un proceso con media constante.
- La varianza no es constante sino que depende del tiempo:
 $Var(y_t) = Var(y_0 + \sum_i w_i) = t\sigma^2$.

¿Cómo extraer la tendencia en la práctica?

- Si la tendencia es determinista mediante regresión. (Se puede eliminar también mediante diferenciación pero resulta una serie cuyas propiedades no son correctas).
- Si la tendencia es estocástica mediante diferenciación.

Valencia Bayesian Research group

Así si X_t es un proceso con tendencia puramente estocástica. X_t es $I(2)$ ΔX_t es $I(1)$ $\Delta^2 X_t$ es $I(0)$, estacionario.

- Si la estacionalidad es puramente determinista mediante regresión.
- Si es estocástica tomando diferencias estacionales




Figure 1




Figure 2




Figure 3




Figure 4

Análisis de los modelos univariantes

- Estos modelos se caracterizan porque para conocer la dinámica de una variable se utiliza información sobre su pasado.
- No son modelos econométricos en el sentido que no utilizan formas funcionales que vienen dadas por la teoría económica. Sin embargo, la información que proporcionan estos modelos suele ser de mucha utilidad para el analista económico ya que proporciona información sobre las características del proceso.

Valencia Bayesian Research group

Transformando las series de modo que en vez de considerar los datos originales se utilizan sus incrementos o los incrementos de los incrementos (si la serie presenta estacionalidad uno de dichos incrementos será estacional) tales transformaciones **no muestran evolución en el nivel y por lo tanto son estacionarias**.

Valencia Bayesian Research group

La evolución tendencial de una serie que implica un determinado modelo se define a partir de su número de diferencias que incluye además del orden polinomial determinista

$$X_t = X_{t-1} + 0.5 + w_t$$

$$X_t = 2X_{t-1} - X_{t-2} + w_t$$

$$X_t = X_{t-1} + 0.5t + w_t$$

$$X_t = 2X_{t-1} - X_{t-2} + 0.5 + w_t$$

Los elementos determinantes en la definición de tendencia

- Los modelos del tipo

$$X_t = a + bt + W_t$$

$$X_t = X_{t-1} + b + W_t$$

- Pero si los parámetros a y b cambian con el periodo de predicción, los modelos integrados de orden 2 resultarán mejores para series con crecimiento sistemático.
- Asimismo un modelo integrado de orden 1 sería mejor que un modelo con un elevado número de rupturas deterministas para las series con oscilaciones locales de nivel.
- Box-Jenkins propone el uso del número máximo de diferencias.

Procesos estocásticos estacionarios

Supongamos que para una determinada serie eliminamos su tendencia con d diferencias regulares y D diferencias estacionales. Es importante tener en cuenta que en series económicas el número de diferencias totales, $d + D$, no debe ser nunca superior a 2.

Valencia Bayesian Research group

Por ejemplo, veamos un caso extremo de crecimiento de precios en una serie mensual.

Indice de precios al consumo en Venezuela




Figure 5

logaritmo natural del índice de precios al consumo en Venezuela




Figure 6

Incluso tras la transformación logarítmica vemos que la evolución de la serie es no lineal aproximadamente en el periodo que va desde 1980 hasta el 2000.

Procesos estocásticos estacionarios.

Si dispusiéramos de varias realizaciones de un proceso entonces la media para cada una de las variables podría ser estimada mediante:

$$\mu = \frac{\sum_{j=1}^m y_t^{(j)}}{m}$$

Sin embargo en la práctica sólo tenemos una realización por lo que no es posible estimar los momentos de las variables que componen el proceso.

Valencia Bayesian Research group

Un **proceso estocástico es estacionario** si:

- La media es constante: $E(y_t) = \mu$ para todo t .
- La varianza es constante: $Var(y_t) = \sigma^2$
- La covarianza entre dos variables separadas h periodos sólo depende de h :
 $cov(y_t, y_{t+h}) = \gamma(h)$

Valencia Bayesian Research group

En la práctica la restricción de estacionariedad nos permite estimar las covarianzas (medida de dependencia lineal entre observaciones separadas h periodos en el tiempo) mediante la covarianza muestral.

$$\hat{\gamma}(h) = \frac{\sum_{t=h+a}^T (y_t - \bar{y})(y_{t+h} - \bar{y})}{T}$$

Correlación y Correlograma


- La estimación de correlaciones es más útil no depende de las unidades de medida de la serie.

$$\hat{\rho} = \frac{\hat{\gamma}(k)}{\hat{\gamma}(0)}$$

- El gráfico de las autocorrelaciones para diferentes valores de k constituyen el **correlograma**.


Valencia Bayesian Research group

```
library(forecast)
Acf(wineind)
```




Pacf(wineind)


Series wineind



```
taperedacf(wineind, nsim = 50)
```



```
taperedpacf(wineind, nsim = 50)
```



El proceso ruido blanco

Valencia Bayesian Research group

Definición

El objetivo de las series temporales es descomponer la serie observada en una parte que es dependiente del pasado y otra que es impredecible:

$$y_t = f(y_{t-1}, y_{t-2}, \dots, y_1) + a_t$$

El proceso a_t se conoce como innovación y tiene la característica de ser **ruido blanco**:

- $E(a_t) = 0$
- $Var(a_t) = \sigma_a^2$
- $cov(a_t, a_{t+h}) = 0$

- El ruido blanco se puede interpretar como un elemento de innovación o sorpresa que vamos a incorporar en nuestro modelo.
- Si todas las series que observamos en la realidad fuesen ruido blanco serían impredecibles y no habría ningún modelo que proponer.

Valencia Bayesian Research group

Teorema de Wold

Cualquier proceso estacionario y_t con media cero se puede representar de la forma

$$y_t = \sum_{j=0}^{\infty} \psi_j \epsilon_{t-j} + k_t$$

- El proceso ϵ_t es ruido blanco y representa el error resultante de predecir y_t con una función lineal de los retardos de y_t :

$$\epsilon_t = y_t - E(y_t | y_{t-1}, y_{t-2}, \dots)$$

- A k_t se llama el componente linealmente determinístico.

Funciones de autocovarianzas y autocorrelaciones

- Funciones de autocorrelación miden la relación lineal entre variables aleatorias de procesos separadas de una cierta distancia en el tiempo.
- Estimación de estas funciones permiten determinar la forma del procesos estocástico.

Valencia Bayesian Research group

- La función de autocovarianza

$$\gamma_{t,s} = \text{Cov}(x_t, x_{t+s}) = E[(x_t - \mu_t)(x_{t+s} - \mu_{t+s})] \quad s = \dots, -1, 0, 1, \dots$$

- Si el proceso es estacionario, su esperanza es constante a largo del tiempo, y la función de autocovarianza no depende del momento en tiempo, sólo la distancia temporal.

$$\gamma_t = E [(x_t - \mu)(x_{t+s} - \mu)]$$

Valencia Bayesian Research group

- Para cada retardo hay un valor diferente para la función de autocovarianzas, autocovarianza de orden s .
- Función de autocorrelación simple ACF (*autocorrelation function*)

$$\rho_{t,s} = \frac{\gamma_{t,s}}{\sqrt{\gamma_{t,s}\gamma_t}} = \frac{E[(x_t - \mu_t)(x_{t+s} - \mu_{t+s})]}{\sqrt{E[(x_t - \mu_t)]^2 E[(x_{t+s} - \mu_{t+s})]^2}}$$

Si el proceso es estacionario, los momentos de segundo orden no dependen de t .

$$\rho_s = \frac{\gamma_s}{\gamma_0} = \frac{E[(x_t - \mu)(x_{t+s} - \mu)]}{E[(x_t - \mu)]^2}$$

- Un correlograma muestra el ACF en función de s

Definimos el momento central de orden k como: $\mu^k = E[(x - E(x))^k]$.

Valencia Bayesian Research group

Función de autocorrelación parcial

La función de autocorrelación parcial PACF (*partial autocorrelation function*) enseña la relación lineal cuando se ha eliminado la correlación que estas variables tienen con otras variables.

$$\phi_{kk} = \text{Corr}(x_t, x_{t-k} | x_{t-1}, \dots, x_{t-k+1})$$

$$\phi_{kk} = \frac{\text{Cov}[(x_t - \hat{x}_t), (x_{t-k} - \hat{x}_{t-k})]}{\sqrt{\text{Var}(x_t - \hat{x}_t) \text{Var}(x_{t-k} - \hat{x}_{t-k})}}$$

- Se pueden obtener los coeficientes de las ACF a través de los modelos lineales:

$$\begin{cases} X_t = \phi_{11}X_{t-1} + \nu_t \\ X_t = \phi_{21}X_{t-1} + \phi_{22}X_{t-2} + \nu_t \\ \dots \\ X_t = \phi_{k1}X_{t-1} + \phi_{k2}X_{t-2} + \dots + \phi_{kk}X_{t-k} + \nu_t \end{cases}$$

Valencia Bayesian Research group

Se puede demostrar que los coeficientes de FAS se pueden escribir como una función de coeficientes de PACF. Esta relación se llama el sistema de ecuaciones de Yule-Walker.

a (sistema d') equacions de **Yule-Walker**:⁸

$$\begin{cases} \rho_1 = \phi_{k1} + \phi_{k2}\rho_1 + \dots + \phi_{kk}\rho_{k-1} \\ \rho_2 = \phi_{k1}\rho_1 + \phi_{k2} + \dots + \phi_{kk}\rho_{k-2} \\ \dots \\ \rho_k = \phi_{k1}\rho_{k-1} + \phi_{k2}\rho_{k-2} + \dots + \phi_{k,k-1}\rho_1 + \phi_{kk} \end{cases} \quad (2)$$

per a $k = 1, 2, \dots$. Aquest sistema d'equacions es pot escriure com:

$$\begin{pmatrix} \phi_{k1} \\ \phi_{k2} \\ \vdots \\ \phi_{kk} \end{pmatrix} = \begin{pmatrix} 1 & \rho_1 & \rho_2 & \dots & \rho_{k-1} \\ \rho_1 & 1 & \rho_1 & \dots & \rho_{k-2} \\ \vdots & \vdots & \vdots & & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \dots & 1 \end{pmatrix}^{-1} \begin{pmatrix} \rho_1 \\ \rho_2 \\ \vdots \\ \rho_k \end{pmatrix},$$

del qual interessa conèixer únicament el valor de ϕ_{kk} . Aplicant la regla de Cramer s'obté aquest valor com a cocient de dos determinants:

$$\phi_{kk} = \frac{\begin{vmatrix} 1 & \rho_1 & \rho_2 & \dots & \rho_{k-2} & \rho_1 \\ \rho_1 & 1 & \rho_1 & \dots & \rho_{k-3} & \rho_2 \\ \vdots & \vdots & \vdots & & \vdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \dots & \rho_1 & \rho_k \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \rho_2 & \dots & \rho_{k-2} & \rho_{k-1} \\ \rho_1 & 1 & \rho_1 & \dots & \rho_{k-3} & \rho_{k-2} \\ \vdots & \vdots & \vdots & & \vdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \dots & \rho_1 & 1 \end{vmatrix}}$$

El primer coeficiente de la PACF coincidirá siempre con el del ACF.

Función de autocorrelación simple

$$\hat{\rho}_s = r_s = \frac{\gamma_s}{\gamma_0} = \frac{\sum_{t=1}^{T-s} (x_t - \bar{x})(x_{t+s} - \bar{x})}{\sum_{t=1}^T (x_t - \bar{x})^2}$$

Valencia Bayesian Research group

Random Walk

Valencia Bayesian Research group


Procesos de paseo aleatorio

Un proceso estocástico sigue un paseo aleatorio si $x_t = x_{t-1} + \varepsilon_t$, donde ε_t es **ruido blanco**.

- El valor en un momento es el valor del periodo anterior más un efecto aleatorio ruido blanco.

$$x_t - x_{t-1} = \Delta x_t = (1 - L)x_t = \varepsilon_t$$

Valencia Bayesian Research group



Valencia Bayesian Research group

Random Walk con media

Se puede incorporar al modelo una cierta constante:

$$\Delta x_t = \delta + \varepsilon_t, \rightarrow x_t = x_{t-1} + \delta + \varepsilon_t$$

Valencia Bayesian Research group

ACF y PACF con R

Valencia Bayesian Research group

Atmospheric concentration of CO2

The record of the atmospheric concentration of CO2 collected at the Mauna Loa Observatory in Hawaii


```
library(RCurl)
## get CO2 data from Mauna Loa observatory
ww1 <- "ftp://aftp.cmdl.noaa.gov/products/"
ww2 <- "trends/co2/co2_mm_mlo.txt"
CO2 <- read.table(text = getURL(paste0(ww1, ww2)))[, c(1, 2,
  5)]
## assign better column names
colnames(CO2) <- c("year", "month", "ppm")
```

Table 1: atmospheric concentration of CO2

year	month	ppm
1958	3	315.71
1958	4	317.45
1958	5	317.50

Creando el objeto 'Serie Temporal'

```
## create a time series (ts) object from the CO2 data
co2 <- ts(data=CO2$ppm, frequency=12,
          start=c(CO2[1,"year"],CO2[1,"month"]))
## plot the ts
plot.ts(co2, ylab=expression(paste("CO" [2], " (ppm)")))
```



Combinado diferentes series

```
## get N Hemisphere land & ocean temperature anomalies from NOAA
Temp <- read_csv("https://www.ncdc.noaa.gov/cag/global/time-series
                 /nhem/land_ocean/p12/12/1880-2014.csv" , skip =
## create ts object
tmp <- ts(data=Temp$Value, frequency=12, start=c(1880,1))
```

x

-0.01

-0.28


-0.30

-0.07

0.03

-0.06


[1] 682 2




Descomponiendo las series

```
co2.decomp <- decompose(co2)
plot(co2.decomp, yax.flip = TRUE)
```

Decomposition of additive time series




Decomposition of additive time series




Diferenciando la series con el comando *diff*

```
## twice-difference the CO2 data
co2.D2 <- diff(co2, differences = 2)
## plot the differenced data
plot(co2.D2, ylab = expression(paste(nabla^2, "CO"[2])))
```




```
## difference the differenced CO2 data
co2.D2D12 <- diff(co2.D2, lag=12)
## plot the newly differenced data
plot(co2.D2D12,
      ylab=expression(paste(nabla, "(", nabla^2, "CO"[2], ")")))

```




Correlogramas

```
## correlogram of the CO2 data
acf(co2, lag.max = 36)
```



```
## correlogram of the CO2 data  
pacf(co2, lag.max = 36)
```



Ejemplos de correlogramas



Creamos primero una función más a nuestro gusto:

```
plot.acf <- function(ACFobj) {
  rr <- ACFobj$acf[-1]
  kk <- length(rr)
  nn <- ACFobj$n.used
  plot(seq(kk), rr, type = "h", lwd = 2, yaxs = "i", xaxs = "i",
        ylim = c(floor(min(rr)), 1), xlim = c(0, kk + 1), xlab = "Lag",
        ylab = "Correlation", las = 1)
  abline(h = -1/nn + c(-2, 2)/sqrt(nn), lty = "dashed", col = "blue")
  abline(h = 0)
}
```



Valencia Bayesian Research group

```
## create sine wave
tt <- sin(2 * pi * seq(nn)/12)
## set up plot area
par(mfrow = c(1, 2))
## plot line
plot.ts(tt, ylab = expression(italic(x[t])))
## get ACF
sine.acf <- acf(tt, plot = FALSE)
## plot ACF
plot.acf(sine.acf)
```

Valencia Bayesian Research group



```
## create sine wave with trend
tt <- sin(2 * pi * seq(nn)/12) - seq(nn)/50
## set up plot area
par(mfrow = c(1, 2))
## plot line
plot.ts(tt, ylab = expression(italic(x[t])))
## get ACF
sili.acf <- acf(tt, plot = FALSE)
## plot ACF
plot.acf(sili.acf)
```




Autocorrelogramas parciales

Creemos primero una función retocada

```
plot.pacf <- function(PACFobj) {
  rr <- PACFobj$acf
  kk <- length(rr)
  nn <- PACFobj$n.used
  plot(seq(kk), rr, type = "h", lwd = 2, yaxs = "i", xaxs = "i",
       ylim = c(floor(min(rr)), 1), xlim = c(0, kk + 1), xlab = "Lag",
       ylab = "PACF", las = 1)
  abline(h = -1/nn + c(-2, 2)/sqrt(nn), lty = "dashed", col = "blue")
  abline(h = 0)
}
```

Valencia Bayesian Research group

```
## PACF of the CO2 data  
co2.pacf <- pacf(co2)
```



```
## correlogram of the CO2 data  
plot.acf(co2.pacf)
```



White Noise

Generamos un W-N.

```
set.seed(123)
## random normal variates
GWN <- rnorm(n = 100, mean = 5, sd = 0.2)
## random Poisson variates
PWN <- rpois(n = 50, lambda = 20)
```

Lo pintamos:

```
## set up plot region
par(mfrow = c(1, 2))
## plot normal variates with mean
plot.ts(GWN)
abline(h = 5, col = "blue", lty = "dashed")
## plot Poisson variates with mean
plot.ts(PWN)
abline(h = 20, col = "blue", lty = "dashed")
```



Y veamos sus autocorrelogramas

```
## set up plot region
par(mfrow = c(1, 2))
## plot normal variates with mean
acf(GWN, main = "", lag.max = 20)
## plot Poisson variates with mean
acf(PWN, main = "", lag.max = 20)
```

Valencia Bayesian Research group



```
## set up plot region
par(mfrow = c(1, 2))
## plot normal variates with mean
acf(GWN, main = "", lag.max = 20)
## plot Poisson variates with mean
acf(PWN, main = "", lag.max = 20)
```

Valencia Bayesian Research group


Random Walk

```
## set random number seed
set.seed(123)
## length of time series
TT <- 100
## initialize {x_t} and {w_t}
xx <- ww <- rnorm(n = TT, mean = 0, sd = 1)
## compute values 2 thru TT
for (t in 2:TT) {
  xx[t] <- xx[t - 1] + ww[t]
}
```

Valencia Bayesian Research group



1st RW



2nd RW

