

# Introducción a Series temporales

Modelos AR, MA, ARMA, ARIMA

Patricia Kisbye  
FaMAF.

1 de noviembre de 2019

# Qué es una serie de tiempo

## Series de tiempo:

Una **serie de tiempo** es un conjunto de datos indexados con un orden temporal:







$$(x_t)_{t \in T}, \quad T \subset \mathbb{R}$$

- $T$  discreto: serie temporal discreta.
- $T$  un intervalo real: serie temporal continua.

# Ejemplos de series de tiempo

- Precios de productos financieros, índices, tasas de interés, inflación, PBI, etc.
- Producción anual de trigo, maíz, exportaciones, etc.
- Población, tasas de natalidad, mortalidad, accidentes, crímenes,
- Medicina: electrocardiograma, encefalogramas, etc.
- FAMAFA: cantidad de inscriptos, alumnos, egresados, etc. por año.

# Gráficos de una serie de tiempo




## Objetivos:

- Modelos probabilísticos que permitan entender y describir los procesos aleatorios que generan la serie temporal.
- Predicción de valores futuros.
- Control de procesos.

# Características de una serie de tiempo

- La serie  $x_1, x_2, x_3, \dots, x_T$ :
  - una muestra de tamaño  $T$  de un proceso estocástico, o
  - $T$  observaciones de  $T$  variables aleatorias, no independientes.
- La dependencia entre los valores de la serie no permite aplicar el análisis estadístico usual.
- Para definir algunos modelos estadísticos, una primera aproximación es suponer estacionariedad de la serie, es decir, que la serie se *comporte siempre igual*.
- ¿Qué significa que sea **estacionaria**?

# Estacionariedad



Serie de tiempo:  $x_1, x_2, x_3, \dots, x_T$

## Proceso estrictamente estacionario

La distribución conjunta de  $(x_{t_1}, x_{t_2}, \dots, x_{t_k})$  es la misma que la distribución conjunta de  $(x_{t_1+h}, x_{t_2+h}, \dots, x_{t_k+h})$  para cualquier subconjunto  $(x_{t_1}, x_{t_2}, \dots, x_{t_k})$ . Sólo puede depender de  $h$ .

En la práctica son procesos difíciles de encontrar.

## Proceso (débilmente) estacionario

$E[x_t] < \infty$ ,  $Var(x_t) < \infty$ , y:

- $E[x_t] = \mu$ , es una constante independiente de  $t$ .
- $Cov(x_t, x_{t+h}) = \gamma_h$ , depende de  $h$ , no de  $t$ .
  
- $\gamma_h$ : Autocovarianza del retardo  $h$ .
- $\rho_h$ : Autocorrelación del retardo  $h$

$$\rho_h = \frac{Cov(x_t, x_{t+h})}{\sqrt{Var(x_t)}\sqrt{Var(x_{t+h})}} = \frac{\gamma_h}{\gamma_0} \quad -1 \leq \rho_h \leq 1.$$
$$\rho_0 = 1.$$

---

```
import statsmodels.tsa.api as stm
...
stm.graphics.plot_acf(serie, lags = 20)
```

---




Figura: Función de autocorrelación

Si la serie es estacionaria y  $\lim_{h \rightarrow \infty} \rho_h = 0$  (condición suficiente), entonces existen estimadores consistentes:

- $\hat{\mu}$  para la media:

$$\hat{\mu} = \frac{1}{T} \sum_{t=1}^T x_t$$

- $\hat{\gamma}_h$  para las autocovarianzas:

$$\frac{1}{T} \sum_{t=1}^{T-h} (x_t - \hat{\mu})(x_{t+h} - \hat{\mu}).$$

```
import quandl
```

```
quandl.get("NSE/SPYL", start_date="2011-01-12", end_date="2013-01-01")
```



Figura: Función de autocorrelación

## Ruido blanco

Es un proceso  $a_t$  con las siguientes propiedades:

- Media 0:  $E[a_t] = 0$ .
- Varianza finita constante:  $Var(a_t) = \sigma_a^2 < \infty$ .
- Autocovarianzas nulas:  $Cov(a_t, a_{t+h}) = 0$  para  $h \neq 0$ .
- Si cada  $a_t$  tiene distribución normal:  $a_t \sim N(0, \sigma_a)$ , se trata de un **Ruido blanco Gaussiano**.





Figura: Ruido blanco

# Series de tiempo lineales

## Series lineales

Son las series que pueden escribirse como

$$x_t = \mu_t + a_t + \psi_1 a_{t-1} + \psi_2 a_{t-2} + \dots,$$

donde  $\mu_t$  es la media y  $\{a_t\}$  es un ruido blanco.

- $a_t$ : es la **innovación** del proceso en tiempo  $t$ .
- Para las series lineales débilmente estacionarias  $\mu_t = \mu$ .

**Teorema de Wold:** Toda serie estacionaria con media 0 y sin componente determinística puede escribirse de esa forma, con la condición:

$$\sum_{j=1}^{\infty} |\psi_j| < \infty.$$

# Caminata aleatoria

## Caminata aleatoria

Es un proceso estocástico  $x_t$  que satisface:

$$x_t = x_{t-1} + a_t,$$

donde  $a_t$  es un ruido blanco.

Notamos que:

$$x_t = x_{t-1} + a_t = x_{t-2} + a_{t-1} + a_t = x_{t-3} + a_{t-2} + a_{t-1} + a_t = \dots$$

$$x_t = x_0 + a_t + a_{t-1} + \dots + a_1 = x_0 + \sum_{j=0}^{t-1} a_{t-j}$$

- No es estacionaria. Tiene una tendencia estocástica:  
 $Var(x_t) = t\sigma_a^2$ .




Figura: Caminata aleatoria

# Ejemplo

## Ejemplo

$$x_t = rx_{t-1} + a_t$$

$a_t$  un ruido blanco.

$$\begin{aligned}x_t &= rx_{t-1} + a_t = r(rx_{t-2} + a_{t-1}) + a_t \\ &= r^2x_{t-2} + ra_{t-1} + a_t = r^2(rx_{t-3} + a_{t-2}) + ra_{t-1} + a_t \\ &= r^3x_{t-3} + r^2a_{t-2} + ra_{t-1} + a_t\end{aligned}$$

$$x_t = r^t x_0 + \sum_{j=0}^{t-1} r^j a_{t-j}$$

- Si  $|r| < 1$  la suma  $\sum_j r^j$  es convergente.
- Si  $|r| < 1$  la serie es estacionaria.

# Modelos Autorregresivos

- $AR(p)$ . El valor de  $x_t$  depende de observaciones anteriores:  $x_{t-1}, x_{t-2}, \dots$
- $MA(q)$ . Las observaciones dependen linealmente de innovaciones anteriores:  $a_{t-1}, a_{t-2}, \dots$
- $ARMA(p, q)$ . Combinaciones de ambas
- **Series integradas**  $I(p)$ . No estacionarias, pero sus diferencias  $x_t - x_{t-1}$  (o de orden mayor) sí.
- $ARIMA(p, I, q)$ . Combinaciones de las tres.
- **ARCH(p), GARCH(p,q)**. Las innovaciones  $a_t$  condicionales no tienen varianza constante.
- Muchos otros.

## AR(p)

- Son modelos **A**uto**R**egresivos, de orden  $p$ .
- Estos modelos intentan explicar la  $i$ -ésima observación a partir de las observaciones anteriores.
- Según el número de observaciones anteriores consideradas es el orden  $p$ .

$$x_t = \phi_0 + \phi_1 x_{t-1} + a_t \quad AR(1)$$

$$x_t = \phi_0 + \phi_1 x_{t-1} + \phi_2 x_{t-2} + a_t \quad AR(2)$$

- $a_t$ : innovación, es un ruido blanco.

# Modelo $AR(1)$

$$x_t = \phi_0 + \phi_1 x_{t-1} + a_t$$

- **Predicción:** Dado  $x_{t-1}$ , el valor **esperado** de  $x_t$  es  $\phi_0 + \phi_1 x_{t-1}$ :

$$\hat{x}_t = E[x_t \mid \text{tiempo pasado}] = \phi_0 + \phi_1 x_{t-1}$$

- Si la serie es estacionaria:

$$\mu = \frac{\phi_0}{1 - \phi_1} \qquad x_t - \mu = \phi_1(x_{t-1} - \mu) + a_t$$

- Restando la media  $\mu$  se trabaja directamente con:

$$x_t = \phi_1 x_{t-1} + a_t.$$

- Es estacionario si y sólo si  $|\phi_1| < 1$ .

# Modelo $AR(p)$ - Autocorrelaciones

- La ACF de un  $AR(1)$  es

$$\rho_h = \phi_1^h, \quad h > 0.$$

- Para un  $AR(2)$ :  $\rho_h = \phi_1 \rho_{h-1} + \phi_2 \rho_{h-2}$ ,  $h > 2$ .
- La ACF no da demasiada información para distinguir un  $AR(p)$ .

## Autocorrelación parcial (PACF)


*Es la correlación entre  $x_t$  y  $x_{t+l}$  quitando la dependencia sobre  $x_{t+1}, x_{t+2}, \dots, x_{t+l-1}$ .*

- Si es un  $AR(p)$ , se anulan todas las autocorrelaciones parciales desde  $p + 1$  en adelante.


# Modelo AR(1)

```
phi = 0.6  
ar = np.r_[1, -phi], ma = np.r_[1,0]  
arl = smt.arma_generate_sample(ar=ar, ma=ma, nsample=n)
```


Análisis gráfico de serie temporal



Autocorrelación




Autocorrelación parcial




# Modelo AR(1)

```
phi = -0.6  
ar = np.r_[1, -phi], ma = np.r_[1,0]  
arl = smt.arma_generate_sample(ar=ar, ma=ma, nsample=n)
```


Análisis gráfico de serie temporal



Autocorrelación



Autocorrelación parcial



# Propiedades $AR(2)$

$$x_t = \phi_0 + \phi_1 x_{t-1} + \phi_2 x_{t-2} + a_t$$

- Si es débilmente estacionario:  $\mu = \frac{\phi_0}{1-\phi_1-\phi_2}$
- Función de autocorrelación ACF:  $\rho_l = \phi_1 \rho_{l-1} + \phi_2 \rho_{l-2}$ .
- Para que sea débilmente estacionaria, las raíces de

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

deben tener valor absoluto mayor que 1.

- Estas propiedades se generalizan a un  $AR(p)$ .




Figura: Modelo AR(2)

# El operador Lag o Retardo

## Operador Retardo

$$Lx_t = x_{t-1}, \quad L^2x_t = x_{t-2}, \quad \dots \quad L^kx_t = x_{t-k}$$

- Un proceso  $AR(p)$ :

$$x_t = \phi_1x_{t-1} + \phi_2x_{t-2} + \dots + \phi_px_{t-p} + a_t$$

- lo podemos escribir como:

$$\underbrace{(1 - (\phi_1L + \phi_2L^2 + \dots + \phi_pL^p))}_{=\Phi(L)}x_t = a_t.$$

- Si las raíces del polinomio  $\Phi(z) = (1 - (\phi_1z + \phi_2z^2 + \dots + \phi_pz^p))$  tienen módulo mayor que 1: [invertibilidad](#).

$$x_t = \Psi(L)a_t = a_t + \psi_1a_{t-1} + \psi_2a_{t-2} + \dots$$

# Modelos MA(q)

## MA(q)

- Son modelos de **media móvil: MovingAverage**, de orden  $q$ .
- Estos modelos intentan explicar la  $i$ -ésima observación a partir de las innovaciones anteriores.
- Según el número de observaciones anteriores consideradas es el orden  $q$ .

$$x_t = \mu + a_t - \theta_1 a_{t-1} \quad MA(1)$$

$$x_t = \mu + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} \quad MA(2)$$

- $a_t$ : innovación, es un ruido blanco.
- $\mu$ : es la media del proceso.

# Propiedades de $MA(q)$

$$x_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \cdots - \theta_q a_{t-q}.$$

- Son siempre (débilmente) estacionarias.
- Para un  $MA(1)$ ,

$$\rho_1 = \frac{-\theta_1}{1 + \theta_1^2}, \quad \rho_h = 0, \quad h > 1.$$

- Para un  $MA(q)$ :


$$\rho_h = 0 \quad h > q$$

- La Función de Autocorrelación Parcial (PACF) no da mayor información.


# Modelo MA(1)

```
theta = 0.6  
ar = np.r_[1, .0], ma = np.r_[1,-theta]  
ar1 = smt.arma_generate_sample(ar=ar, ma=ma, nsample=n)
```


Análisis gráfico de serie temporal



Autocorrelación




Autocorrelación parcial



# Modelo MA(1)

```
theta = -0.6  
ar = np.r_[1, .0], ma = np.r_[1, -theta]  
ar1 = smt.arma_generate_sample(ar=ar, ma=ma, nsample=n)
```



# Modelos ARMA( $p, q$ )

$$ARMA(p, q)$$

- **A**uto **R**egresive **M**oving **A**verage.
- Son modelos que conjugan a los autorregresivos con los de media móvil.
- $a_t$ : innovación, es un ruido blanco.

## ARMA(1,2)

$$\underbrace{x_t - \phi_1 x_{t-1}}_{AR(1)} = \phi_0 + \underbrace{a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2}}_{MA(2)}$$

# Series integradas

Si tenemos una serie de tiempo  $x_t$ , podemos:

- **diferenciarla:**

$$\Delta x_t = x_t - x_{t-1}$$



- y luego **integrarla:**

$$x_t = x_{t-1} + \Delta x_t.$$

## Series $I(1)$

Una serie es **integrada de orden 1** si al diferenciarla **una vez** resulta estacionaria.

Ejemplos: precios de activos, índices, tasas de interés.



# Raíces unitarias

- Si en un modelo AR(p) ocurre:

$$1 - \phi_1 - \phi_2 - \dots - \phi_p = 0$$

se dice que el proceso tiene un **raíz unitaria**.

- Los procesos con raíz unitaria no son estacionarios. Se pueden transformar en un proceso estacionarios diferenciando:

una vez	$x_t - x_{t-1} = \Delta x_t = (I - L)x_t$
dos veces	$(x_t - x_{t-1}) - (x_{t-1} - x_{t-2}) = (I - L)^2 x_t$
...	...

- Para testear la presencia de raíces unitarias: **Test ADF**: Augmented Dickey Fuller Test.

# Modelos ARIMA

## Modelo $ARIMA(p, d, q)$

Un proceso es un  $ARIMA(p, d, q)$  si al diferenciarlo  $d$  veces resulta un  $ARMA(p, q)$ .

- Predicción en un  $ARIMA(2, 1, 1)$ :


$$x_t - x_{t-1} = \phi_0 + \phi_1 x_{t-1} + \phi_2 x_{t-2} - a_t - \theta_1 a_{t-1}$$

- Dadas las observaciones  $x_1, x_2, \dots, x_h$ :

$$\hat{x}_{h+1} = E[x_{h+1} \mid \text{observaciones anteriores}]$$

$$= x_h + \phi_0 + \phi_1 x_h + \phi_2 x_{h-1} - \theta_1 a_h$$

$$\text{Error} = a_{h+1}$$



# Muchas gracias,



Patricia.