

Análisis Estadístico de Datos Climáticos

SERIES TEMPORALES 2

2015

Contenido

- **Procesos estacionarios y débilmente estacionarios**
- **Algunos procesos estocásticos útiles:**

Procesos puramente aleatorios (ruido blanco)

Caminatas al azar

Procesos auto-regresivos

Media, varianza y autocovarianza de procesos (o modelos) estocásticos

Partimos de un **proceso estocástico**: un conjunto de variables aleatorias ordenadas en el tiempo y definidas en un conjunto de instantes, que pueden ser discretos o continuos.

Para el caso discreto, anotamos X_t , para referir a la variable aleatoria en el instante t . ($t = 0, \pm 1, \pm 2, \dots$).

Una serie real es una realización particular del proceso estocástico. La anotamos x_t con $t = 1, 2, \dots, N$, para el caso discreto.

Definimos (o recordamos) algunos conceptos útiles:

Media: $\mu(t) = E(X_t)$ para todo t .

Varianza: $\sigma^2(t) = \text{Var}(X_t)$ para todo t .

Función de autocovarianza (f. acv): es la covarianza de X_{t_1} y X_{t_2} , o sea:

$$\gamma(t_1, t_2) = E[(X_{t_1} - \mu(t_1))(X_{t_2} - \mu(t_2))] \text{ para todo } t_1 \text{ y } t_2.$$

(La varianza es un caso particular de la covarianza, para $t_1 = t_2$.)

Procesos (o modelos) estacionarios

Un proceso es **estrictamente estacionario** si la distribución conjunta de X_{t_1}, \dots, X_{t_k} es la misma que la distribución conjunta de $X_{t_1+\tau}, \dots, X_{t_k+\tau}$, para todo t_1, \dots, t_k , τ y k .

En otras palabras, trasladar el origen de tiempos en una magnitud τ no tiene efecto en las distribuciones conjuntas, las cuales dependerán solamente de los intervalos entre t_1, t_2, \dots, t_k .

En particular, para $k=1$, la estacionariedad estricta implica que la distribución de X_t es la misma para todo t , por lo que, se cumplirá que:

$$\mu(t) = \mu$$

$$\sigma^2(t) = \sigma^2$$

para todo t (si existen).

Además, si $k=2$ la distribución conjunta de X_{t_1} y X_{t_2} depende sólo de la diferencia $(t_2 - t_1) = \tau$, que se llama **lag**.

Procesos (o modelos) estacionarios

Entonces, la f. acv $\gamma(t_1, t_2)$ también depende sólo de $(t_2 - t_1)$ y se puede escribir como $\gamma(\tau)$, siendo

$$\gamma(\tau) = E[(X_t - \mu)(X_{t+\tau} - \mu)] = \text{Cov}(X_t, X_{t+\tau}),$$

que recibe el nombre de coeficiente de autocovarianza en el lag τ .

Notar que $\gamma(0) = \text{Var}(X_t) = \sigma^2$

La f. acv se estandariza para obtener la **función de autocorrelación** (adimensionada), que se define como:

$$\rho(\tau) = \gamma(\tau) / \gamma(0) = \gamma(\tau) / \sigma^2$$

$\rho(\tau)$ es la correlación entre X_t y $X_{t+\tau}$.

(La función de autocorrelación muestral, para $\tau = k$, es la r_k que ya hemos definimos antes.)

En lo que sigue, para los procesos discretos escribiremos $\rho(k)$ y $\gamma(k)$.

Procesos débilmente estacionarios (o estacionarios de segundo orden)

En la práctica es útil definir un concepto de estacionariedad menos estricto.

Un proceso es **débilmente estacionario** si su media es constante y su f. acv depende sólo del lag, o sea:

$$E(X_t) = \mu$$

y

$$\text{Cov}(X_t, X_{t+\tau}) = \gamma(\tau)$$

(Tomando $\tau = 0$, tenemos que la varianza también es constante para un proceso débilmente estacionario.)

Un caso particular importante es cuando el proceso es gaussiano, o sea cuando la distribución conjunta de X_{t_1}, \dots, X_{t_k} es normal multivariada para todos los t_1, \dots, t_k , ya que esta última queda caracterizada completamente por sus primer y segundo momentos. Entonces, para estos procesos, la estacionariedad débil implica la estacionariedad estricta.

Algunas propiedades de la acv y la ac

Sea un proceso estocástico estacionario X_t con media μ , varianza σ^2 , función de autocovarianza $\gamma(\tau)$ y función de autocorrelación $\rho(\tau)$.

- Ya vimos que $\rho(\tau) = \gamma(\tau)/\gamma(0) = \gamma(\tau)/\sigma^2$
Notar que $\rho(0) = 1$

- $\gamma(\tau) = \gamma(-\tau)$
 $\rho(\tau) = \rho(-\tau)$

- $|\rho(\tau)| \leq 1$

Algunos procesos (o modelos) útiles

1. Procesos puramente aleatorios (“ruido blanco”)

Se llama así a un proceso en que los términos $\{Z_t\}$ son variables aleatorias mutuamente independientes e idénticamente distribuidos (iid). Habitualmente se supone además que las variables aleatorias tienen distribución normal con media cero y varianza σ_Z^2 , que serán constantes para todo t .

La suposición de independencia implica que:

$$\begin{aligned}\gamma(k) &= \text{Cov}(Z_t, Z_{t+k}) = \sigma_Z^2 \text{ si } k=0 \\ &= 0 \text{ si } k= \pm 1, \pm 2, \dots\end{aligned}$$

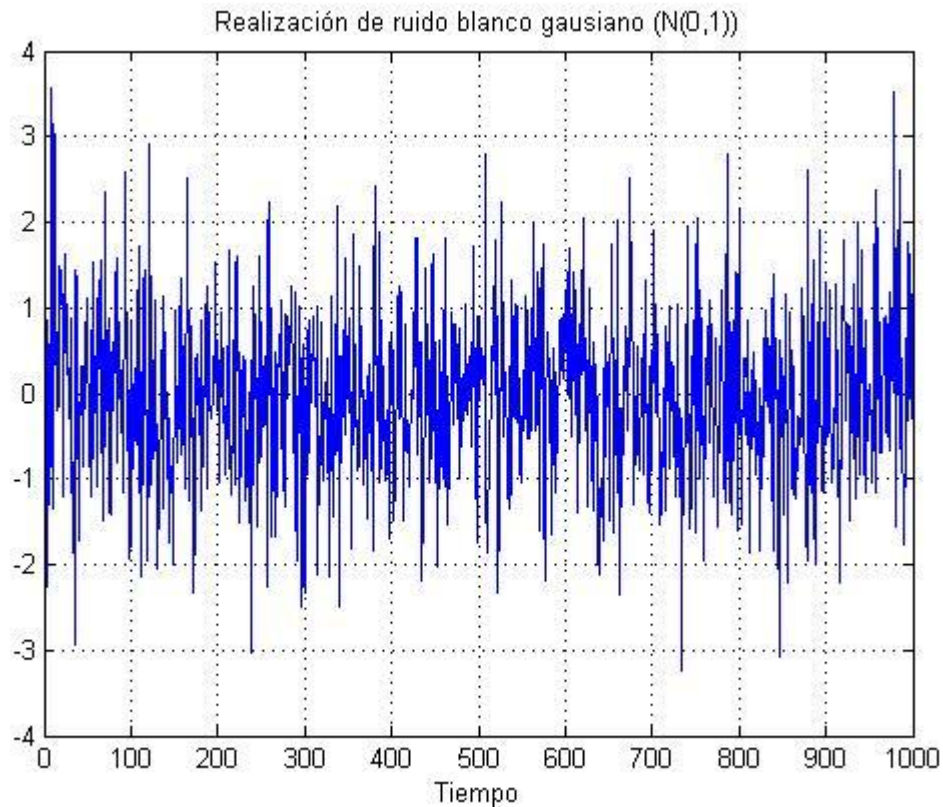
lo cual implica que:

$$\begin{aligned}\rho(k) &= 1 \text{ si } k = 0 \\ &= 0 \text{ si } k= \pm 1, \pm 2, \dots\end{aligned}$$

Este proceso es, por definición, estrictamente estacionario.

Ejemplo: una realización de ruido blanco gaussiano ($N(0,1)$)

```
Y=randn(1,1000);  
plot(Y), grid
```



El ruido blanco aparece como un componente en varios otros procesos estocásticos.

2. Caminatas al azar (“random walks”)

Si $\{Z_t\}$ es un proceso puramente aleatorio con media μ y varianza σ^2 , se dice que el proceso X_t es una **caminata al azar** si

$$X_t = X_{t-1} + Z_t$$

Suponiendo que se comienza con $X_1 = Z_1$, tenemos que

$$X_t = \sum_{i=1}^t Z_i$$

Se tiene que: $E(X_t) = t\mu$ y $\text{Var}(X_t) = t\sigma_Z^2$

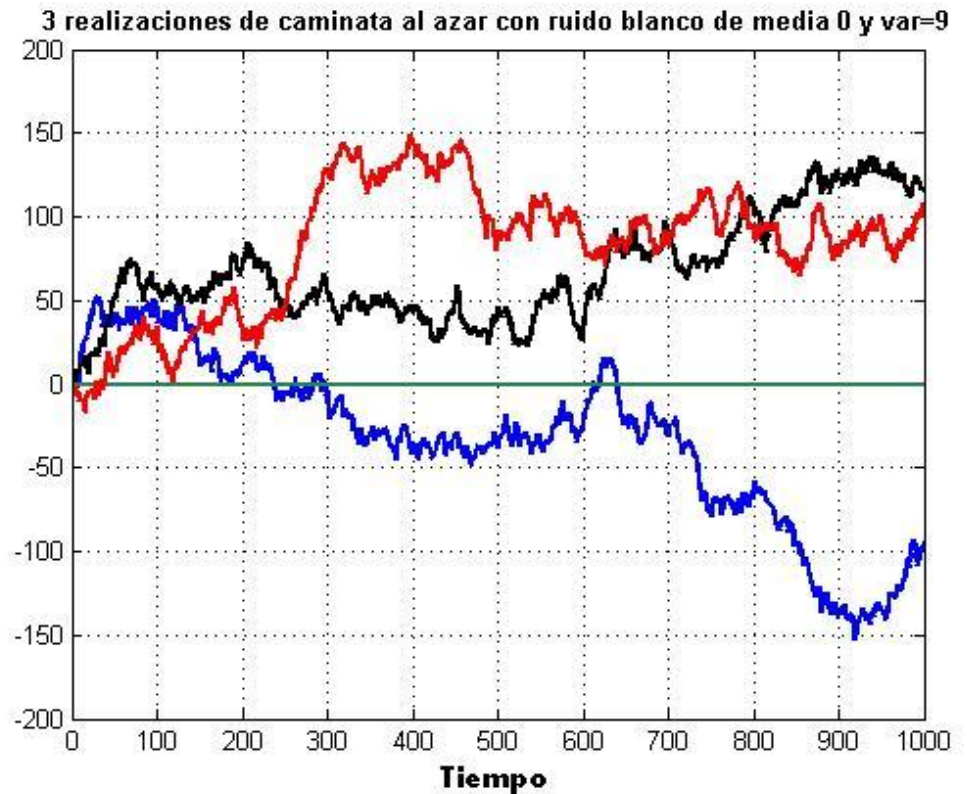
Por lo tanto, el proceso no es estacionario.

(pero $X_t - X_{t-1} = Z_t$ es puramente aleatorio y por tanto es estacionario.)

Ejemplo: 3 realizaciones de una caminata al azar con ruido blanco gaussiano de varianza = 9.

```
X=zeros(1,1000);  
for i=2:1000;  
    X(i)=X(i-1)+3*randn;  
end  
plot(X)  
% ejecutada 3 veces
```

La media “no cambia” para valores grandes de t, pero la dispersión sí “crece” con t.



Aplicación a dispersión de contaminantes en la atmósfera (Von Storch – Zwiers, p. 202-203)

Una caminata al azar describe la trayectoria de una partícula que realiza desplazamientos aleatorios.

El movimiento de una partícula, p. ej. emitida por una chimenea o un volcán está determinada por el flujo determinístico U y muchos pequeños desplazamientos impredecibles.

Si la partícula en t está en la ubicación R(t), en t+1 estará en

$R(t+1) = R(t) + U + Z_t$ (donde Z_t es ruido blanco con media 0),

y en el instante t+k estará en:

$$R(t+k) = R(t) + kU + \sum_{i=t}^{i=t+k-1} Z_i$$

La aplicación a muchas partículas, puede permitir modelar su dispersión tridimensional.




Figure 10.6: *Example of a simulation of long-range transport of air pollutants.*
 Left: *Simulated 1000 hPa height field 24 hours after model initialization.*
 Right: *Distribution of pollutant continuously emitted in east England after 24 hours.*
 From Lehnhaus et al. [250].

A la izquierda, un pronóstico de alturas de geopotencial en 1000 hPa para Europa occidental.

Se “inyecta” SO₂ en la atmósfera simulada en un punto del este de Inglaterra.

A la derecha, la concentración de SO₂ producida por el modelo estocástico a las 24 hs.

3. Procesos auto-regresivos (AR)

Si Z_t es un proceso puramente aleatorio con media 0 y varianza σ_z^2 (ruido blanco), se dice que el proceso $\{X_t\}$ es un **proceso auto-regresivo de orden p (AR(p))** si

$$X_t = \alpha_1 X_{t-1} + \alpha_2 X_{t-2} + \dots + \alpha_p X_{t-p} + Z_t$$

En cierto sentido, se puede interpretar como un modelo de regresión lineal múltiple, pero la regresión es respecto de valores pasados de X_t , y no respecto de variables predictoras independientes.

El AR de primer orden ($p=1$),

$$X_t = \alpha X_{t-1} + Z_t \quad (1)$$

se llama a veces proceso de Markov o también proceso de “ruido rojo”.

Este proceso tiene interés porque hay muchas variables climáticas, geofísicas e índices solares que presentan un espectro similar al de un proceso de ruido rojo (el espectro lo veremos más adelante). (Para el caso particular $\alpha = 0$, el proceso es de ruido blanco.)

Se puede demostrar que este proceso es estacionario si $|\alpha| < 1$.

En ese caso, $E(X_t)$ debe ser una constante para todo t , que se halla tomando valores esperados en la ecuación (1), resultando $E(X_t) = 0$.


Si elevamos (1) al cuadrado y tomamos valores esperados, llegamos a que $\sigma_X^2 = \sigma_Z^2 / (1 - \alpha^2)$

**Si multiplicamos (1) por X_{t-k} y tomamos valores esperados, obtenemos: $\gamma(k) = \alpha\gamma(k-1)$;
luego usando que $\gamma(0) = \sigma_X^2$, llegamos a que**

$$\gamma(k) = \alpha^k \sigma_X^2$$

y



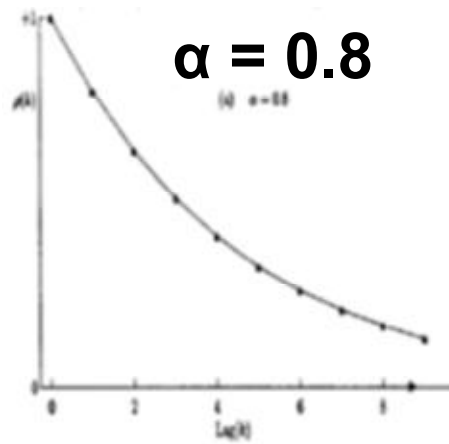
$$\rho(k) = \alpha^k$$



2 realizaciones de AR(1), con $\alpha = 0.3$ y $\alpha = 0.9$.

Observar que la segunda tiene mucho más persistencia que la primera, que se parece más a la realización de un ruido blanco.

Figure 10.7: 240 time step realizations of AR(1) processes with $\alpha_1 = 0.3$ (top) and 0.9 (bottom). Both processes are forced by unit variance normally distributed white noise.



Correlogramas de AR(1)

Figure 3.1 Three examples of the autocorrelation function of a first-order autoregressive process with, (a) $a=0.8$; (b) $a=0.3$; (c) $a=-0.8$.

Para los AR(p) existen condiciones entre los coeficientes para que exista estacionariedad