

# Introducción a los Procesos Estocásticos

Germán Capdehourat, Sergio Martínez, Pablo Musé  
{gcapde, sematag, pmuse}@fing.edu.uy

Instituto de Ingeniería Eléctrica  
Facultad de Ingeniería



UNIVERSIDAD  
DE LA REPÚBLICA  
URUGUAY

10 de agosto de 2021

Introducción

Caracterización de procesos estocásticos

Procesos estocásticos estacionarios (sentido estricto)

Procesos estocásticos estacionarios (sentido amplio)

Relación entre estacionariedad amplia y estricta

Estimación de autocorrelaciones de procesos WSS

Filtrado lineal de procesos estacionarios

- ▶ Casi cualquier sistema de utilidad es diseñado para **procesar entradas que no se conocen**
  - ⇒ Mejora de señales de **voz**, restauración de **grabaciones o películas antiguas**
  - ⇒ Compresión de **audio, imágenes o video**
  - ⇒ Reducción de **ruido** y detección de señales de **radar**
  - ⇒ Señales de origen **geofísico, astronómico, biológico, etc.**
- ▶ **Que las señales no se conozcan exactamente no significa que de ellas no se sepa nada.** Se pueden conocer o estimar ciertas **propiedades estadísticas**
  - ⇒ E.g. señales de voz: aunque siempre distintas, tienen ancho de banda conocido, forma de onda y espectro reconocibles

- ▶ El estudio de **procesos estocásticos** formaliza el conocimiento sobre las **señales aleatorias**, a partir su **caracterización estadística**
  - ⇒ Con esta caracterización estadística se puede **diseñar y estudiar sistemas alimentados con esta clase de entradas**.
- ▶ Buena parte de la **popularidad del enfoque probabilístico** se debe a su **éxito en la aplicación a sistemas de comunicación**
  - ⇒ Claude Shannon. *A Mathematical Theory of Communication*. The Bell System Technical Journal, 1948. **Lectura fundamental!!!**


- ▶ Limitaremos la exposición a señales unidimensionales
- ▶ Las definiciones se pueden extender a señales de dimensión mayor:
  - ⇒ Imágenes (dos dimensiones  $x$  e  $y$ )
  - ⇒ Secuencias de video (tres dimensiones  $x$ ,  $y$ ,  $t$ ), etc.

**Def:** Un **proceso estocástico** es una función aleatoria de dos variables,  $X(\omega, t)$ ,  $\omega \in \Omega$  un suceso, y  $t \in T$  un índice temporal

- ▶ Fijado  $t = t_0$ ,  $X(\omega, t_0)$  es una **variable aleatoria**
- ▶ Para cada experimento (elección de  $\omega$ ), la realización  $X(\omega, t)$  es una **función del tiempo**. Extensión de la noción de VA a funciones
- ▶  $T = \mathbb{R}$  para procesos continuos,  $T = \mathbb{N}, \mathbb{Z}$  para procesos discretos
- ▶ Es usual hacer abuso de notación y escribir  $X(t)$
- ▶ Salvo que se indique, trabajaremos con procesos reales:  $X(t) \in \mathbb{R}$ .

**Transmisión de secuencia de bits independientes.** Cada bit toma el valor '1' con probabilidad  $p$ , '0' con probabilidad  $1 - p$ , indep. del resto.


$\Rightarrow \{X_n, n = 1, 2, \dots\}$  proceso i.i.d. con distrib. de Bernoulli( $p$ ).



**Señal portadora en comunicaciones.** En el receptor, se modela como

$$X(t) = \cos(2\pi ft + \Theta), \quad \text{con } \Theta \sim \mathcal{U}[-\pi, \pi).$$

⇒ **Fase aleatoria: incertidumbre del receptor** sobre cuándo se prendió el transmisor, o sobre su distancia.




# Ejemplo: Movimiento Browniano o proceso de Wiener

Camino errático, movimiento de partículas en un fluido, cotización de acciones en bolsa, etc.

$\{W(t), t \geq 0\}$  tal que:

- ▶  $W(0) = 0$
- ▶ **Incrementos independientes:** para todo  $t > 0$ , los incrementos futuros  $W(t+u) - W(t)$ ,  $u \geq 0$  son independientes de los valores pasados  $W(s)$ ,  $s < t$
- ▶ **Incrementos Gaussianos:**  $W(t+u) - W(t) \sim \mathcal{N}(0, u)$
- ▶ **Realizaciones o caminos continuos:**  $W(t)$  continua para todo  $t > 0$ .





# Caracterización de procesos estocásticos

Introducción

Caracterización de procesos estocásticos

Procesos estocásticos estacionarios (sentido estricto)

Procesos estocásticos estacionarios (sentido amplio)

Relación entre estacionariedad amplia y estricta

Estimación de autocorrelaciones de procesos WSS

Filtrado lineal de procesos estacionarios

Un proceso estocástico  $X(t)$  está **totalmente caracterizado** cuando podemos determinar su distribución conjunta

$$F_{t_1, \dots, t_n}(x_1, \dots, x_n) = P(X(t_1) \leq x_1, \dots, X(t_n) \leq x_n),$$

para todo conjunto de tiempos  $t_1, \dots, t_n$ ,  $1 \leq n < +\infty$ .

Usualmente: **cdfs conj. desconocidas, debemos estimarlas de los datos**

- ▶ **Costo computacional prohibitivo**  $\Rightarrow$  **Caracterizaciones parciales**
- ▶ Usualmente: caracterizaciones parciales de una o dos VAs  $X(t_1)$ ,  $X(t_2)$ : **medias, varianzas, correlaciones**

# Funciones de media, autocorrelación y autocovarianza

Sea el proceso estocástico  $\{X(t), t \in T\}$ .

**Def:** Para todo valor de  $t$ ,  $X(t)$  es una VA de media  $\mathbb{E}[X(t)]$ . Llamamos **función de media** del proceso  $X(t)$  a la función

$$m_X(t) := \mathbb{E}[X(t)].$$

- ▶ Refleja el comportamiento medio del proceso a lo largo del tiempo.

**Def:** Para todo  $t_1, t_2 \in T$ , llamamos **función de autocorrelación** del proceso  $X(t)$  en  $t_1, t_2$  a la función

$$R_X(t_1, t_2) := \mathbb{E}[X(t_1)X(t_2)],$$

y **función de autocovarianza** a

$$\begin{aligned} C_X(t_1, t_2) &:= \mathbb{E}[(X(t_1) - m_X(t_1))(X(t_2) - m_X(t_2))] \\ &= R_X(t_1, t_2) - m_X(t_1)m_X(t_2). \end{aligned}$$

- ▶ Corresponde a la correlación/covarianza entre las VAs  $X(t_1)$  y  $X(t_2)$
- ▶ Refleja cuán suave o variante es el proceso en el tiempo.

- ▶ La función de autocorrelación es simétrica:

$$R_X(t_1, t_2) = \mathbb{E}[X(t_1)X(t_2)] = \mathbb{E}[X(t_2)X(t_1)] = R_X(t_2, t_1)$$

- ▶  $R_X(t, t) = \mathbb{E}[X^2(t)] \geq 0$

- ▶ Por la desigualdad de Cauchy-Schwarz,  $\forall t_1, t_2$ ,

$$|R_X(t_1, t_2)| = |\mathbb{E}[X(t_1)X(t_2)]| \leq \sqrt{\mathbb{E}[X^2(t_1)]\mathbb{E}[X^2(t_2)]}.$$

- ▶ La autocorrelación es una función semi-definida positiva:

$$\forall c_1, \dots, c_n \in \mathbb{R}, \quad \sum_{i=1}^n \sum_{j=1}^n c_i R_X(t_i, t_j) c_j \geq 0.$$

En efecto,  $\sum_i \sum_j c_i \mathbb{E}[X(t_i)X(t_j)] c_j = \sum_i \sum_j \mathbb{E}[c_i X(t_i)X(t_j) c_j]$   
 $= \mathbb{E} \left[ \sum_i c_i X(t_i) \sum_j c_j X(t_j) \right] = \mathbb{E} \left[ \left| \sum_i c_i X(t_i) \right|^2 \right] \geq 0.$

**Def:** Decimos que  $X(t)$  es un **proceso de segundo orden** si  $\forall t$ ,  $\mathbb{E}[X^2(t)] < +\infty$ .

Si  $X(t)$  es de segundo orden,

- ▶ La media es finita:

$$|\mathbb{E}[X(t)]| = |\mathbb{E}[X(t) \cdot 1]| \leq \sqrt{\mathbb{E}[X^2(t_1)] \mathbb{E}[1^2]} = \sqrt{\mathbb{E}[X^2(t_1)]}.$$

- ▶ La autocorrelación es finita:

$$|R_X(t_1, t_2)| \leq \sqrt{\mathbb{E}[X^2(t_1)] \mathbb{E}[X^2(t_2)]}.$$

- ▶ La autocovarianza es finita (por serlo la autocorrelación y la media).

# Ejemplo: paseo al azar (*random walk*)

Proceso de incrementos no correlacionados  $\{Y_n = \sum_{i=1}^n X_i, n \geq 0\}$   
con  $X_i = \pm\Delta$ ,  $P(X_i = +\Delta) = P(X_i = -\Delta) = 1/2$

$$m_Y(n) = \mathbb{E} \left[ \sum_{i=1}^n X_i \right] = \sum_{i=1}^n \mathbb{E} [X_i] = n \left( \frac{\Delta}{2} - \frac{\Delta}{2} \right) = 0$$

$$\text{var} [Y_n] = \sum_{i=1}^n \text{var} [X_i] = n \mathbb{E} [X_i^2] = n \Delta^2$$

(i)  $m > n$ :

$$\begin{aligned} R_Y(n, m) &= \mathbb{E} [Y_n Y_m] = \mathbb{E} \left[ Y_n (Y_n + \sum_{i=n+1}^m X_i) \right] \\ &= \mathbb{E} [Y_n^2] + \mathbb{E} \left[ Y_n \sum_{i=n+1}^m X_i \right] = n \Delta^2 \end{aligned}$$



ya que

$$\blacktriangleright \mathbb{E} [Y_n] = 0 \Rightarrow \mathbb{E} [Y_n^2] = \text{var} [Y_n] = n \Delta^2$$

$$\begin{aligned} \blacktriangleright \mathbb{E} \left[ Y_n \sum_{i=n+1}^m X_i \right] &= \\ \mathbb{E} [Y_n] \mathbb{E} \left[ \sum_{i=n+1}^m X_i \right] &= 0. \end{aligned}$$


(ii)  $m \leq n$ :  $R_Y(n, m) = m \Delta^2$

Luego,  $\forall m, n, R_Y(n, m) = \Delta^2 \min\{m, n\}$



# Ejemplo: Onda binaria aleatoria

Sea el proceso estocástico  $\{X_n, n \in \mathbb{Z}\}$ , donde las  $X_n$  son i.i.d. y toman los valores  $+1$  y  $-1$  con probabilidad  $1/2$ . Consideramos la señal  $Y(t) = AX_n$  en el intervalo  $[nT + \varepsilon, (n+1)T + \varepsilon]$ , con  $\varepsilon \sim \mathcal{U}[0, T]$ , independiente de los  $X_n$ .



► ¿Media y autocorrelación de  $Y(t)$ ?

**Obs.:** Podemos escribir

$$Y(t) = \sum_{n=-\infty}^{+\infty} X_n A h(t - (nT + \varepsilon)), \quad \text{con } h(t) = \begin{cases} 1, & 0 \leq t \leq T \\ 0, & \text{en caso contrario.} \end{cases}$$

## Ejemplo: Onda binaria aleatoria (cont.)

Usando **linealidad de la esperanza**, **independencia de las VAs** y  $\mathbb{E}[X_n] = 0$ ,

$$m_Y(t) = \mathbb{E}_{X_{\mathbb{Z}}, \varepsilon}[Y(t)] = A \sum_{n=-\infty}^{+\infty} \mathbb{E}_{X_n}[X_n] \mathbb{E}_{\varepsilon}[h(t - (nT + \varepsilon))] = 0$$

$$\begin{aligned} R_Y(t_1, t_2) &= \mathbb{E}_{X_{\mathbb{Z}}, \varepsilon}[Y(t_1)Y(t_2)] \\ &= A^2 \sum_{n=-\infty}^{+\infty} \sum_{m=-\infty}^{+\infty} \mathbb{E}_{X_n, X_m}[X_n X_m] \mathbb{E}_{\varepsilon}[h(t_1 - (nT + \varepsilon))h(t_2 - (mT + \varepsilon))] \end{aligned}$$

Como

$$\mathbb{E}_{X_n, X_m}[X_n X_m] = \begin{cases} \mathbb{E}[X_n] \mathbb{E}[X_m] = 0, & n \neq m \\ \mathbb{E}[X_n^2] = \frac{1}{2}(-1)^2 + \frac{1}{2}(1)^2 = 1, & m = n, \end{cases}$$


$$\begin{aligned} R_Y(t_1, t_2) &= A^2 \sum_{n=-\infty}^{+\infty} \mathbb{E}_{\varepsilon}[h(t_1 - (nT + \varepsilon))h(t_2 - (nT + \varepsilon))] \\ &= A^2 \sum_{n=-\infty}^{+\infty} \frac{1}{T} \int_0^T h(t_1 - (nT + \varepsilon))h(t_2 - (nT + \varepsilon))d\varepsilon. \end{aligned}$$



# Ejemplo: Onda binaria aleatoria (cont.)

Con el **cambio de variable**  $\phi = t_1 - (nT + \varepsilon)$ , obtenemos

$$\begin{aligned} R_Y(t_1, t_2) &= A^2 \sum_{n=-\infty}^{+\infty} \frac{1}{T} \int_{t_1 - (n+1)T}^{t_1 - nT} h(\phi) h(t_2 - t_1 + \phi) d\phi \\ &= A^2 \frac{1}{T} \int_{-\infty}^{\infty} h(\phi) h(t_2 - t_1 + \phi) d\phi \\ &= \begin{cases} A^2 \left(1 - \frac{|t_2 - t_1|}{T}\right), & |t_2 - t_1| < T \\ 0, & \text{en caso contrario.} \end{cases} \end{aligned}$$



# Procesos estocásticos estacionarios (sentido estricto)

Introducción

Caracterización de procesos estocásticos

Procesos estocásticos estacionarios (sentido estricto)

Procesos estocásticos estacionarios (sentido amplio)

Relación entre estacionariedad amplia y estricta


Estimación de autocorrelaciones de procesos WSS

Filtrado lineal de procesos estacionarios

# Procesos estocásticos estacionarios (sentido estricto)

Intuitivamente, un proceso estacionario es aquel para el cual sus propiedades estadísticas no cambian en el tiempo.

- ▶ **Ej:** Sintonizamos un receptor FM en un canal libre. El ruido de fondo que escuchamos es estacionario ya que suena siempre igual: no cambia de volumen ni de sonido con el tiempo.
- ▶ **Ej:** Temperatura global anual.



Anomalies are deviation from baseline (1981-2010 Average).  
The black thin line indicates surface temperature anomaly of each year.  
The blue line indicates their 5-year running mean.  
The red line indicates the long-term linear trend.

Es un proceso no estacionario  
(el calentamiento global es un  
hecho).

# Procesos estocásticos estacionarios (sentido estricto)

**Def:** Un proceso estocástico es **estrictamente estacionario al orden  $n$**  si, para todo conjunto de  $n$  tiempos  $t_1, t_2, \dots, t_n$ , la distribución conjunta

$$F_{t_1+\Delta t, \dots, t_n+\Delta t}(x_1, \dots, x_n) = P(X(t_1 + \Delta t) \leq x_1, \dots, X(t_n + \Delta t) \leq x_n)$$

es independiente de  $\Delta t$ , para cualquier  $\Delta t$ .

Si el proceso es estrictamente estacionario de orden  $n$  para todo  $n$  entero positivo, decimos que es **estacionario en sentido estricto (SSS)**.

- ▶ Su estadística es **invariante ante translaciones**
- ▶ Su estadística **sólo depende de la diferencia de tiempo entre instantes considerados**.
- ▶ **Ex:** Una proceso  $X(t)$  i.i.d.  $\sim F(x)$  es estrictamente estacionario:
  - $P(X(t_1 + h) \leq x_1, \dots, X(t_n + h) \leq x_n) = F(x_1) \cdots F(x_n)$ ,
  - ▶ independientemente de la elección de índices  $\{t_1, \dots, t_n\}$ .
  - ▶ cualquiera sea  $F$ .

# Procesos estocásticos estacionarios (sentido estricto)

- ▶ **Verificar la estacionariedad estricta** de orden  $n$  de un proceso requiere calcular todas las cdf (pmf) o pdf conjuntas  $f_{t_1, \dots, t_n}(x_1, \dots, x_n)$  para todo  $(t_1, \dots, t_n) \in T^n \Rightarrow$  **computacionalmente intratable**.  
 $\Rightarrow$  Nos limitaremos (salvo excepciones) a caracterizaciones de orden 2
- ▶ **Aún la estimación de densidades para caracterizaciones de orden 2**,  $f_{X(t_1), X(t_2)}(x_1, x_2)$  para todo  $(t_1, t_2) \in T^2$  es general **intratable**
- ▶ En la práctica, en general es suficiente con verificar la estacionariedad para los dos primeros momentos  
 $\Rightarrow$  estacionariedad en **sentido amplio** (medias y correlaciones)

# Sobre los procesos complejos

Sea  $Z(t) = X(t) + iY(t)$  un proceso complejo ( $X(t)$ ,  $Y(t)$  reales).

- ▶  $Z(t)$  es SSS si  $X(t)$  e  $Y(t)$  son ambos SSS.
- ▶  $\mathbb{E}[Z(t)] = \mathbb{E}[X(t)] + i\mathbb{E}[Y(t)]$ .
- ▶  $R_{XY}(t_1, t_2) = \mathbb{E}[X(t_1)Y(t_2)]$ ,  $R_{YX}(t_1, t_2) = \mathbb{E}[Y(t_1)X(t_2)]$
- ▶ En general los procesos de interés son circulares, i.e. su estadística es invariante a rotaciones:  $\forall t, \forall \phi \in [-\pi, \pi]$  determinístico,

$e^{i\phi}Z(t)$  tiene igual distribución que  $Z(t)$ .

- ▶ Si  $Z(t)$  es circular:

$$R_{YX}(t_1, t_2) = -R_{XY}(t_1, t_2),$$

$$R_Z(t_1, t_2) := \mathbb{E}[Z(t_1)Z^*(t_2)] = 2R_X(t_1, t_2) + 2iR_Y(t_1, t_2),$$

$$\mathbb{E}[Z(t_1)Z(t_2)] = 0, \forall t_1, t_2.$$

# Sobre los procesos complejos (cont.)

Sea  $Z(t) = X(t) + iY(t)$  un proceso complejo circular.

- ▶ La función de autocorrelación es hermítica:

$$R_Z(t_1, t_2) = \mathbb{E} [Z(t_1)Z^*(t_2)] = \mathbb{E} [(Z^*(t_1)Z(t_2))^*] = R_Z^*(t_2, t_1)$$

- ▶  $R_Z(t, t) = \mathbb{E} [Z(t)Z^*(t)] = \mathbb{E} [|Z(t)|^2] \geq 0$

- ▶ Por la desigualdad de Cauchy-Schwarz,  $\forall t_1, t_2$ ,

$$|R_Z(t_1, t_2)| = |\mathbb{E} [Z(t_1)Z^*(t_2)]| \leq \sqrt{\mathbb{E} [|Z(t_1)|^2] \mathbb{E} [|Z(t_2)|^2]}.$$

- ▶ La autocorrelación es una función semi-definida positiva:

$$\forall c_1, \dots, c_n \in \mathbb{C}, \quad \sum_{i=1}^n \sum_{j=1}^n c_i R_X(t_i, t_j) c_j^* \geq 0.$$

En efecto,

$$\begin{aligned} \sum_i \sum_j c_i \mathbb{E} [Z(t_i)Z^*(t_j)] c_j^* &= \sum_i \sum_j \mathbb{E} [c_i Z(t_i)Z^*(t_j) c_j^*] \\ &= \mathbb{E} \left[ \sum_i c_i Z(t_i) \sum_j c_j^* Z^*(t_j) \right] = \mathbb{E} \left[ \left( \sum_i c_i Z(t_i) \right) \left( \sum_j c_j Z(t_j) \right)^* \right] \geq 0. \end{aligned}$$

# Procesos estocásticos estacionarios (sentido amplio)

Introducción

Caracterización de procesos estocásticos

Procesos estocásticos estacionarios (sentido estricto)

Procesos estocásticos estacionarios (sentido amplio)

Relación entre estacionariedad amplia y estricta

Estimación de autocorrelaciones de procesos WSS

Filtrado lineal de procesos estacionarios



# Procesos estocásticos estacionarios (sentido amplio)

**Def:** Un proceso es **estacionario en sentido amplio (WSS)** si satisface las tres propiedades siguientes:

- (i) Es un proceso de segundo orden, i.e.  $\forall t, \mathbb{E}[|X^2(t)|] < +\infty$
- (ii) Su función de media  $\mathbb{E}[X(t)]$  no depende de  $t$ ,
- (iii) Su función de autocorrelación cumple

$$R_X(t_1, t_2) = R_X(t_1 - t_2, 0),$$

i.e. depende de  $t_1$  y  $t_2$  sólo a través de su diferencia  $t_1 - t_2$ , esto es  $C_X(t_1, t_2) = C_X(t_1 + h, t_2 + h) \forall t_1, t_2, h$ .

- Por lo anterior, para procesos WSS

$$R(t + \tau, t) =: R(\tau).$$

- ▶  $R_X(\tau)$  es par:

$$\begin{aligned}R_X(-\tau) &= \mathbb{E}[X(t)X(t-\tau)] \\ &= \mathbb{E}[X(t-\tau)X(t)] \\ &= R_X(t-(t-\tau)) = R_X(\tau).\end{aligned}$$

- ▶  $R_X(0) = \mathbb{E}[X^2(t)] \geq 0$

- ▶  $R_X(\tau) \leq R_X(0)$ :

Por Cauchy-Schwarz,

$$\begin{aligned}R_X(\tau) = \mathbb{E}[X(t+\tau)X(t)] &\leq \sqrt{\mathbb{E}[X^2(t)] \mathbb{E}[X^2(t+\tau)]} \\ &= \sqrt{\mathbb{E}[X^2(t)] \mathbb{E}[X^2(t)]} \\ &= \mathbb{E}[X^2(t)] = R_X(0).\end{aligned}$$

## La onda binaria aleatoria es WSS

Para la onda binaria aleatoria

$$Y(t) = AX_n \quad \text{en el intervalo } [nT + \varepsilon, (n+1)T + \varepsilon],$$


con  $X_n = \pm 1$  i.i.d. equiprobable, y  $\varepsilon \sim \mathcal{U}[0, T]$ , indep. de los  $X_n$ ,

vimos que

$$m_Y(t) = 0$$

$$R_Y(t_1, t_2) = \begin{cases} A^2 \left(1 - \frac{|t_2 - t_1|}{T}\right), & |t_2 - t_1| < T \\ 0, & \text{en caso contrario.} \end{cases}$$

Media constante, autocorrelación sólo depende de  $t_2 - t_1$



Observar que  $R_X(\tau)$  es par y tiene máximo en 0.


## El paseo al azar o *random walk* **no** es WSS

Para el paseo al azar

$\{Y_n = \sum_{i=1}^n X_i, n \geq 0\}$ ,  $X_i$  no correlacionadas,  $\mathbb{E}[X_i] = 0$ ,  $\text{var}[X_i] = \sigma^2$ ,

teníamos

- ▶  $m_Y(n) = 0$
- ▶  $\text{var}[Y_n] = n\sigma^2$
- ▶  $R_Y(m, n) = \sigma^2 \text{mín}\{m, n\}$



Además de que la autocorrelación depende de  $n$  y  $m$  pero no de  $m - n$ ,  
**basta con ver que la varianza depende de  $n$ .**

## Cualquier función de un proceso SSS es un proceso SSS

Demostración.

Sea  $\{X(t), t \in T\}$  un proceso SSS y  $g : \mathbb{R}^m \rightarrow \mathbb{R}$  una función. Definimos el proceso  $\{Y(t), t \in T\}$ ,  $Y(t_k) = g(X(t_k), X(t_{k+1}), \dots, X(t_{k+m-1}))$ .

La distribución conjunta de  $Y(t_1 + h), \dots, Y(t_n + h)$  es

$$\begin{aligned} & P(Y(t_1 + h) \leq y_1, \dots, Y(t_n + h) \leq y_n) \\ &= P(g(X(t_1 + h), \dots, X(t_m + h)) \leq y_1, \\ & \quad \dots, g(X(t_n + h), \dots, X(t_{n+m-1} + h)) \leq y_n) \\ &= P(g(X(t_1), \dots, X(t_n)) \leq y_1, \dots, g(X(t_n), \dots, X(t_{n+m-1})) \leq y_n) \\ &= P(Y(t_1) \leq y_1, \dots, Y(t_n) \leq y_n), \end{aligned}$$

donde la segunda igualdad vale por ser  $\{X(t), t \in T\}$  SSS. Tenemos entonces que  $\{Y(t), t \in T\}$  es SSS. □

## Cualquier función lineal de un proceso WSS es un proceso WSS

Lo veremos para el caso continuo (caso discreto: análogo con sumas)

- ▶  $X(t)$ , media  $m_X$ , autocorrelación  $R_X(\tau)$ .
- ▶ Sistema LTI estable, con respuesta al impulso  $h(t)$ . ( $\|h\|_1 < \infty$ )

⇒ Caracterizar su salida  $Y(t) = \int_{-\infty}^{+\infty} h(u)X(t-u)du$

$$\mathbb{E}[Y(t)] = \int_{-\infty}^{+\infty} h(u) \mathbb{E}[X(t-u)] du = m_X \int_{-\infty}^{+\infty} h(u) du$$

$$\begin{aligned}\mathbb{E}[Y(t+\tau)Y(t)] &= \mathbb{E}\left[\int_{-\infty}^{+\infty} h(u)X(t+\tau-u)du \int_{-\infty}^{+\infty} h(v)X(t-v)dv\right] \\ &= \int_{-\infty}^{+\infty} h(u) \int_{-\infty}^{+\infty} h(v) \mathbb{E}[X(t+\tau-u)X(t-v)] dv du \\ &= \int_{-\infty}^{+\infty} h(u) \int_{-\infty}^{+\infty} h(v) R_X(\tau-u+v) dv du =: R_Y(\tau)\end{aligned}$$

(es válido intercambiar el orden de la esperanza con las integrales, ya que las integrales convergen por ser el filtro estable)

## Cualquier función lineal de un proceso WSS es un proceso WSS

Para procesos en tiempo discreto, igual que para tiempo continuo:

- ▶  $X(n)$ , media  $m_X$ , autocorrelación  $R_X(k) = \mathbb{E}[X(k+j)X(j)]$ .
- ▶ Sistema LTI estable, con respuesta al impulso  $h(n)$ . ( $\|h\|_1 < \infty$ )  
⇒ Caracterizar su salida  $Y(n) = \sum_{k=-\infty}^{+\infty} h(k)X(n-k)$

$$\mathbb{E}[Y(n)] = \sum_{k=-\infty}^{+\infty} h(k) \mathbb{E}[X(n-k)] = m_X \sum_{k=-\infty}^{+\infty} h(k)$$

$$\begin{aligned} \mathbb{E}[Y(k+n)Y(k)] &= \mathbb{E}\left[\sum_{i=-\infty}^{+\infty} h(i)X(n+k-i) \sum_{j=-\infty}^{+\infty} h(j)X(k-j)\right] \\ &= \sum_{i=-\infty}^{+\infty} h(i) \sum_{j=-\infty}^{+\infty} h(j) \mathbb{E}[X(n+k-i)X(k-j)] \\ &= \sum_{i=-\infty}^{+\infty} h(i) \sum_{j=-\infty}^{+\infty} h(j) R_X(n-i+j) =: R_Y(n) \end{aligned}$$

(es válido intercambiar el orden de la esperanza con las sumas, ya que las sumas convergen por ser el filtro estable).

# Relación entre estacionariedad amplia y estricta

Introducción

Caracterización de procesos estocásticos

Procesos estocásticos estacionarios (sentido estricto)

Procesos estocásticos estacionarios (sentido amplio)

Relación entre estacionariedad amplia y estricta

Estimación de autocorrelaciones de procesos WSS

Filtrado lineal de procesos estacionarios



- ▶ **Q:** ¿Un proceso SSS es necesariamente WSS? **NO!**
- ▶ Como la definición de un proceso SSS no requiere que el proceso sea de segundo orden, **SSS no necesariamente implica WSS.**

## Ejemplo

$X(t)$  i.i.d. con distribución de Cauchy estándar  $f(x) = \frac{1}{\pi(x^2+1)}$ .

Tenemos:

- ▶ Como todo proceso i.i.d., su cdf es invariante ante translaciones  $\Rightarrow$  **SSS**
- ▶  $\mathbb{E}[X(t)]$  y  $\mathbb{E}[X^2(t)]$  son infinitas  $\Rightarrow$  **No WSS**

# Relación entre estacionariedad amplia y estricta (cont.)

- ▶ **Q:** ¿Un proceso de segundo orden SSS es necesariamente WSS? **SI**

Demostración.

Como el proceso  $\{X(t), t \in T\}$  es SSS, las VAs

$$X(t_1), X(t_2), \dots$$

tienen todas la misma función de distribución

$\Rightarrow (X(t_1), X(t_2))$  y  $(X(t_1 + h), X(t_2 + h))$  tienen la misma distribución conjunta  $\forall t_1, t_2, h$

Como el proceso es de segundo orden, sus momentos de orden 2 son finitos lo que implica que

- ▶  $\mathbb{E}[X(t)]$  es constante
- ▶  $\forall t_1, t_2, h, R_X(t_1 + h, t_2 + h) = R_X(t_1, t_2)$ .



- ▶ Q: ¿Un proceso WSS es necesariamente SSS? **Claramente NO**

## Ejemplo

Sea  $\{X(n), n \in \mathbb{Z}\}$  un proceso estocástico definido por

$$X(n) = \begin{cases} u(n) & \text{si } n \text{ par} \\ \frac{1}{\sqrt{2}} (u(n)^2 - 1) & \text{si } n \text{ impar} \end{cases},$$

con  $u(n)$  i.i.d.  $\sim \mathcal{N}(0, 1)$ . Este proceso es WSS pero no es SSS.

Demostración.

Ejercicio.



# Relación entre estacionariedad amplia y estricta (cont.)

Existe sin embargo un caso importante para el cual  $WSS \Rightarrow SSS$ :

Si  $\{X(t), t \in T\}$  es un proceso Gaussiano  $WSS \Rightarrow \{X(t), t \in T\}$  es  $SSS$

**¿Por qué?**

# Relación entre estacionariedad amplia y estricta (cont.)

**Def:**  $\{X(t), t \in T\}$  es un **proceso Gaussiano (GP)** si y sólo si toda  $n$ -tupla  $\mathbf{X} := (X(t_1), X(t_2), \dots, X(t_n))^T$  es un conjunto de VAs Gaussianas. La pdf conjunta de  $\mathbf{X}$  es

$$f_{\mathbf{X}}(\mathbf{x}) = \frac{1}{\sqrt{(2\pi)^n \det(\mathbf{C}_{\mathbf{X}})}} \exp\left(-\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu})^T \mathbf{C}_{\mathbf{X}}^{-1}(\mathbf{x} - \boldsymbol{\mu})\right),$$

donde  $\boldsymbol{\mu}$  es su media y  $\mathbf{C}_{\mathbf{X}}$  su matriz de covarianza

$$\boldsymbol{\mu} = \mathbb{E}[\mathbf{X}] = (\mathbb{E}[X(t_1)], \mathbb{E}[X(t_2)], \dots, \mathbb{E}[X(t_n)])^T$$

$$\mathbf{C}_{\mathbf{X}} = \text{cov}(\mathbf{X}, \mathbf{X}) = \begin{pmatrix} \text{cov}(X^2(t_1)) & \text{cov}(X(t_1), X(t_2)) & \dots & \text{cov}(X(t_1), X(t_n)) \\ \text{cov}(X(t_2), X(t_1)) & \text{cov}(X^2(t_2)) & \dots & \text{cov}(X(t_2), X(t_n)) \\ \vdots & \vdots & \ddots & \vdots \\ \text{cov}(X(t_n), X(t_1)) & \text{cov}(X(t_n), X(t_2)) & \dots & \text{cov}(X^2(t_n)) \end{pmatrix}$$

$\implies$  **Totalmente caracterizado por sus dos primeros momentos**

# Relación entre estacionariedad amplia y estricta (cont.)

## Demostración.

Como el proceso es WSS, verifica

- ▶  $\forall t, \mathbb{E}[X(t)] = \mu < +\infty,$
- ▶  $\forall t, \text{var}[X(t)] = \sigma^2 < +\infty$
- ▶  $\forall t_1, t_2, h, \text{cov}(X(t_1 + h), X(t_2 + h)) = \text{cov}(X(t_1), X(t_2))$

Un GP queda determinado por su media y covarianza; como son inv. a traslaciones,  $f_{X(t_1+h), \dots, X(t_n+h)}(\mathbf{x}) = f_{X(t_1), \dots, X(t_n)}(\mathbf{x})$ : el GP es SSS.  $\square$

**Obs:** el recíproco es cierto ya que los procesos Gaussianos son de segundo orden, y por end SSS  $\Rightarrow$  WSS.

$\Rightarrow$  Para procesos Gaussianos, **WSS**  $\Leftrightarrow$  **SSS**

# Estimación de autocorrelaciones de procesos WSS

Introducción

Caracterización de procesos estocásticos

Procesos estocásticos estacionarios (sentido estricto)

Procesos estocásticos estacionarios (sentido amplio)

Relación entre estacionariedad amplia y estricta

Estimación de autocorrelaciones de procesos WSS

Filtrado lineal de procesos estacionarios

# Estimación de autocorrelaciones de procesos WSS

En la práctica no disponemos de la función de autocorrelación y debemos estimarla de los datos. Sea  $\{X(k), k \in \mathbb{Z}\}$  un proceso discreto WSS.

Definimos

$$\langle R_X(n) \rangle_N := \frac{1}{2N+1} \sum_{k=-N}^N X(k+n)X(k).$$

Tenemos

$$\begin{aligned} \mathbb{E} [\langle R_X(n) \rangle_N] &= \frac{1}{2N+1} \sum_{k=-N}^N \mathbb{E} [X(k+n)X(k)] \\ &= \frac{1}{2N+1} (2N+1) R_X(n) = R_X(n) \end{aligned}$$

$\Rightarrow \langle R_X(n) \rangle_N$  es un estimador insesgado de  $R(n)$ .

Los **teoremas ergódicos** (más adelante) aseguran que, bajo ciertas condiciones:

$$\langle R_X(n) \rangle_N \xrightarrow{N \rightarrow +\infty} R_X(n).$$



# Estimación de autocorrelaciones de procesos WSS (cont.)

Para procesos continuos  $\{X(t), t \in \mathbb{R}\}$  WSS, definimos

$$\langle R_X(\tau) \rangle_T := \frac{1}{2T} \int_{-T}^T X(t+\tau)X(t)dt.$$

Tenemos

$$\mathbb{E} \left[ \langle R_X(\tau) \rangle_T \right] = \frac{1}{2T} \int_{-T}^T \mathbb{E} [X(t+\tau)X(t)] dt = R_X(\tau)$$

$\Rightarrow \langle R(\tau) \rangle_T$  es un estimador insesgado de  $R_X(\tau)$ .

Los **teoremas ergódicos** (más adelante) aseguran que, bajo ciertas condiciones:

$$\langle R_X(\tau) \rangle_T \xrightarrow{T \rightarrow +\infty} R_X(\tau).$$

# Filtrado lineal de procesos WSS

Introducción

Caracterización de procesos estocásticos

Procesos estocásticos estacionarios (sentido estricto)

Procesos estocásticos estacionarios (sentido amplio)

Relación entre estacionariedad amplia y estricta

Estimación de autocorrelaciones de procesos WSS

Filtrado lineal de procesos estacionarios

## Tiempo continuo:

La **transformada de Fourier (FT)** de  $R(\tau) \in L^2(\mathbb{R})$  se define como

$$S_X(f) := \int_{-\infty}^{\infty} R_X(\tau) e^{-i2\pi f\tau} d\tau.$$

Por la **fórmula de inversión**,

$$R_X(\tau) = \int_{-\infty}^{\infty} S_X(f) e^{i2\pi f\tau} df.$$

**Propiedad:** Como  $R(\tau)$  es real y par,  $S_X(f)$  es real y par.

## Tiempo discreto:

La **transformada de Fourier en tiempo discreto (DTFT)** de  $R(k) \in \ell^2(\mathbb{Z})$  se define como

$$S_X(e^{i\theta}) := \sum_{k=-\infty}^{\infty} R_X(k) e^{-ik\theta}.$$

Por la **fórmula de inversión**,


$$R_X(\tau) = \frac{1}{2\pi} \int_{-\pi}^{\pi} S_X(e^{i\theta}) e^{ik\theta} d\theta.$$

## Propiedades:

- ▶  $S_X(e^{i\theta})$  es  $2\pi$ -periódica
- ▶ Como  $R(k)$  es real y par,  $S_X(e^{i\theta})$  es real y par.

# Filtrado LTI de procesos WSS

Vimos que un proceso  $X(t)$  WSS, al pasar por un filtro LTI **estable**, produce otro proceso  $Y(t)$  WSS:



$$m_Y = m_X \int_{-\infty}^{+\infty} h(u) du$$

$$R_Y(\tau) = \int_{-\infty}^{+\infty} h(u) \left( \int_{-\infty}^{+\infty} h(v) R_X(\tau - u + v) dv \right) du$$

Antes de seguir con el análisis de  $R_Y(\tau)$  veamos qué sucede con la **correlación cruzada** de  $X(t_1)$  e  $Y(t_2)$

$$\begin{aligned}\mathbb{E}[X(t_1)Y(t_2)] &= \int_{-\infty}^{+\infty} h(u)\mathbb{E}[X(t_1)X(t_2 - u)] du \\ &= \int_{-\infty}^{+\infty} h(u)R_X(t_1 - t_2 + u) du\end{aligned}$$

Dos procesos  $X(t)$ ,  $Y(t)$ , ambos WSS, se dicen **conjuntamente WSS (J-WSS)** si su correlación cruzada  $\mathbb{E}[X(t_1)Y(t_2)]$  depende sólo de  $t_1 - t_2$ .

$$\begin{aligned}R_{XY}(\tau) &:= \mathbb{E}[X(t + \tau)Y(t)] = \int_{-\infty}^{+\infty} h(v)\mathbb{E}[X(t + \tau)X(t - v)] dv \\ &= \int_{-\infty}^{+\infty} h(v)R_X(\tau + v) du \stackrel{\{w=-v\}}{=} \int_{-\infty}^{+\infty} h(-w)R_X(\tau - w) dw\end{aligned}$$

Si definimos  $\bar{h}(w) = h(-w)$ , tenemos:  $R_{XY}(\tau) = \bar{h} * R_X(\tau)$

Volviendo a la autocorrelación de la salida del LTI,  $Y(t)$ :


$$\begin{aligned} R_Y(\tau) &= \int_{-\infty}^{+\infty} h(u) \left( \int_{-\infty}^{+\infty} h(v) R_X(\tau - u + v) dv \right) du \\ &= \int_{-\infty}^{+\infty} h(u) R_{XY}(\tau - u) du = h * R_{XY}(\tau) \end{aligned}$$

Como  $R_{XY}(\tau) = \bar{h} * R_X(\tau)$ , tenemos

$$R_Y(\tau) = h * R_{XY}(\tau) = h * \bar{h} * R_X(\tau)$$

con  $\bar{h}(u) = h(-u)$ .

## Análisis en el dominio de las frecuencias



- ▶ La transferencia del filtro es  $\hat{h}(f) = \int_{-\infty}^{+\infty} h(t)e^{-i2\pi ft} dt$ .
- ▶ La FT de  $R_X(\tau)$  es  $S_X(f) = \int_{-\infty}^{+\infty} R_X(\tau)e^{-i2\pi f\tau} d\tau$ .
- ▶ La FT de  $R_{XY}(\tau)$  vale:


$$S_{XY}(f) = \mathcal{F} \{ \bar{h} * R_X \} (f) \stackrel{\{\bar{h}(u)=h(-u)\}}{=} \hat{h}^*(f) S_X(f)$$

- ▶ La FT de  $R_Y(\tau)$  vale:

$$S_Y(f) = \mathcal{F} \{ h * R_{XY} \} (f) = \hat{h}(f) S_{XY}(f) = \left| \hat{h}(f) \right|^2 S_X(f)$$



## Tiempo discreto (ejercicio del práctico)



- ▶ La transferencia del filtro es  $\hat{h}(e^{i\theta}) = \sum_{n=-\infty}^{+\infty} h(n)e^{-in\theta}$ .
- ▶ La DTFT de  $R_X(k)$  es  $S_X(e^{i\theta}) = \sum_{k=-\infty}^{+\infty} R_X(k)e^{-ik\theta}$ .
- ▶ La DTFT de  $R_{XY}(k)$  vale:

$$S_{XY}(e^{i\theta}) = \mathcal{F}\{\bar{h} * R_X\}(e^{i\theta}) \stackrel{\{\bar{h}(k)=h(-k)\}}{=} \hat{h}^*(e^{i\theta})S_X(e^{i\theta})$$

- ▶ La DTFT de  $R_Y(k)$  vale:

$$S_Y(e^{i\theta}) = \mathcal{F}\{h * R_{XY}\}(f) = \hat{h}(e^{i\theta})S_{XY}(e^{i\theta}) = \left|\hat{h}(e^{i\theta})\right|^2 S_X(e^{i\theta})$$