

- Repaso: correlación cruzada y espectro cruzado de procesos conjuntamente WSS
- Filtro de Wiener: aplicación a degradaciones lineales contaminadas con ruido.

Correlación cruzada, espectro cruzado.

- $x(t), y(t)$ procesos reales, conjuntamente WSS (J-WSS), esto es:
 - = Ambos son WSS
 - = $\mathbb{E}[x(t_1)y(t_2)]$ depende de t_1, t_2 únicamente a través de su diferencia $t_1 - t_2$
- Definimos la correlación cruzada de $x(t)$ y $y(t)$ J-WSS con la convención siguiente:

$$R_{xy}(\tau) = \mathbb{E}[x(t+\tau)y(t)]$$

OBS: A diferencia de la autocorrelación, en donde poco importaba (siempre considerando procesos reales) si sumábamos o restábamos τ en la definición ya fue

$$\begin{aligned} R_x(-\tau) &= \mathbb{E}[x(t)x(t-\tau)] \\ &\stackrel{\text{inv a transl.}}{=} \mathbb{E}[x(t+\tau)x(t+\tau-\tau)] \\ &= \mathbb{E}[x(t+\tau)x(t)] = R_x(\tau), \end{aligned}$$

en la correlación cruzada hay que ser consistente con la definición.

En efecto,

$$\begin{aligned} R_{xy}(-\tau) &= \mathbb{E} [\cancel{x}(t-\tau) y(t)] \\ &= \mathbb{E} [\cancel{x}(t+\tau-\tau) y(t+\tau)] \\ &\stackrel{\text{inv. a}}{=} \mathbb{E} [\cancel{x}(t) y(t+\tau)] \\ &\stackrel{\text{traslacion}}{=} R_{yx}(\tau) \end{aligned}$$

. Definimos el espectro cruzado como

$$S_{xy}(f) = \int_{\mathbb{R}} R_{xy}(\tau) e^{-i2\pi f \tau} d\tau$$

 **OBS:** esto no es una densidad spectral de potencia. Por ejemplo, como en general no tenemos que $R_{xy}(\tau)$ es par, $S_{xy}(f)$ será una función compleja.

$$S_{xy}(-f) = \int R_{xy}(\tau) e^{+i2\pi f \tau} d\tau = S_{xy}^*(f)$$

$$\begin{aligned} S_{xy}(-f) &= \int R_{xy}(\tau) e^{-i2\pi f(-\tau)} d\tau = \left\{ \begin{array}{l} \text{c.v.} \\ \lambda = -\tau \end{array} \right\} \\ &= \int R_{xy}(-\lambda) e^{-i2\pi f \lambda} d\lambda = \int R_{yx}(\lambda) e^{-i2\pi f \lambda} d\lambda = S_{yx}(f) \end{aligned}$$

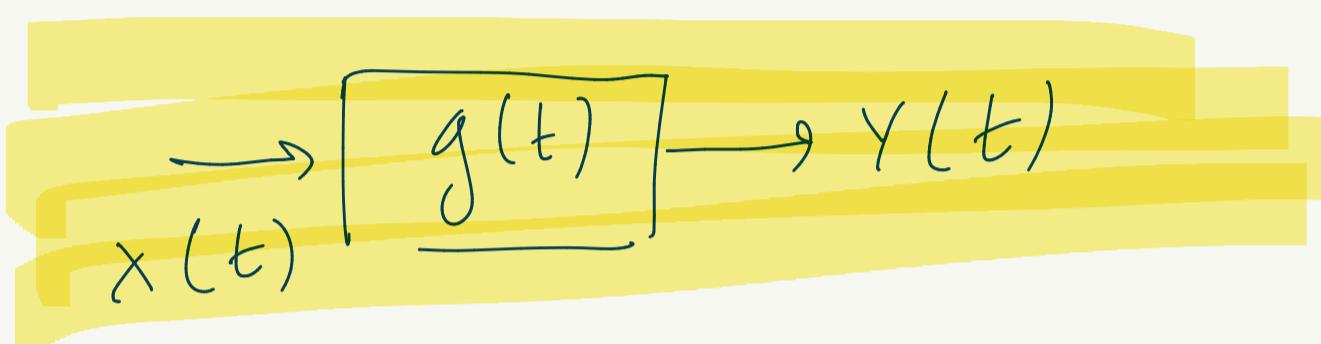
Resumiendo, para
procesos J-WSS

$$\cdot R_{XY}(\tau) = \mathbb{E}[X(t+\tau)Y(t)]$$

reales :

$$\cdot R_{XY}(-\tau) = R_{YX}(\tau)$$

$$\cdot S_{XY}(-f) = S_{XY}^*(f) = S_{YX}(f)$$



• X WSS real

• $g(t)$ resp. al impulso de un LTI estable

Estudiamos la correlación entre la
entrada y la salida del filtro:

$$y(t) = g * x(t) = \int_R g(u) x(t-u) du$$

i) $y(t)$ también es WSS:

$$\mathbb{E}[y(t)] = \int_R g(u) \mathbb{E}[x(t-u)] du = m_x \int g(u) du$$

$$\cdot \mathbb{E}[y(t)y(t+\tau)] =$$

$$\int_R g(u) \int_R g(v) \underbrace{\mathbb{E}[x(t-u)x(t+\tau-v)]}_{(x \text{ WSS})} du dv \xrightarrow{R_X(t+\tau-v-t+u)}$$

(wss)

$$\mathbb{E}[y(t)y(t+\tau)] = \iint_{\mathbb{R}^2} g(u)g(v) R_x(\tau - v + u) du dv$$

(sólo depende de τ , no de t)

$$R_{xy}(t+\tau, t) = \mathbb{E}[x(t+\tau)y(t)]$$

$$= \mathbb{E}\left[x(t+\tau) \int_{\mathbb{R}} g(u)x(t-u) du\right]$$

$$= \int_{\mathbb{R}} g(u) \mathbb{E}[x(t+\tau)x(t-u)] du$$

$$= \int_{\mathbb{R}} g(u) R_x(t+\tau - t + u) du$$

x wss

$$\left\{ \begin{array}{l} \text{c.v.} \\ v = -u \end{array} \right\} = \int_{\mathbb{R}} g(-v) R_x(\tau - v) dv$$

$$\Leftrightarrow R_{xy}(t+\tau, t) = \bar{g} * R_x(\tau)$$

$\therefore R_{xy}$ es inv. a translación.

luego : $\begin{cases} - x(s), y(t) \text{ wss} \\ - R_{xy}(t+\tau, t) \text{ indep de } t \end{cases} \Rightarrow \begin{cases} x(t), y(t) \\ J-WSS \end{cases}$

Filtros de Wiener

Como vimos en clase, la transferencia del filtro de Wiener para la estimación de un proceso (no observado) $v(t)$ a partir de un proceso (observado) $u(t)$ es

$$\hat{h}(f) = \frac{S_{vu}(f)}{S_u(f)}$$

(Atención: respetar las convenciones para $R_{vu}(\tau) = \mathbb{E}[v(t+\tau)v(t)]$
 $S_{vu}(f) = \mathcal{F}\{R_{vu}\}(f)$)

Aplicación: Proceso degradado por filtros LTI y contaminado con ruido:

$$u(t) = g * v(t) + n(t),$$

dónde: . $v(t)$ WSS

. $n(t)$ WSS, de media nula

. $v(t)$ y $n(t)$ independientes

Calculemos el filtro de Wiener para esta degradación:

$$\begin{aligned}
 R_{VU}(\tau) &= E[V(t+\tau)V(t)] \\
 &= E[V(t+\tau)(g * V(t) + N(t))] \\
 &\stackrel{\text{linealidad}}{=} E[V(t+\tau)(g * V(t))] \\
 &\quad + E[V(t+\tau)N(t)]
 \end{aligned}$$

Para el primer término, aplicamos la

relación $R_{XY}(\tau) = \bar{g} * R_X(\tau)$ para

$Y(t) = g * X(t)$, identificando
 $X(t)$ con $V(t)$ y $Y(t)$ con $V(t)$.

$$\rightarrow E[V(t+\tau)(g * V(t))] = \bar{g} * R_V(\tau)$$

Para el segundo término,

$$\begin{aligned}
 E[V(t+\tau)N(t)] &= \underbrace{E[V(t+\tau)]}_{\text{indep}} \underbrace{E[N(t)]}_{=0} \\
 &= 0
 \end{aligned}$$

Tenemos entonces $R_{VV}(\tau) = \bar{g} * R_v(\tau)$.

$$\Rightarrow S_{VV}(f) = \widehat{\bar{g}}(f) \cdot S_v(f)$$

$$\widehat{\bar{g}}(f) = \int \bar{g}(t) e^{-i2\pi ft} dt$$

$$= \int g(-t) e^{-i2\pi ft} dt$$

$$= \int g(u) e^{+i2\pi fu} du = \widehat{g^*}(f)$$

$$R_V(\tau) = E[V(t)V(t+\tau)]$$

$$= E[(g^*V(t) + N(t))(g^*V(t+\tau) + N(t+\tau))]$$

$$= E[(g^*V(t))(g^*V(t+\tau))]$$

$$+ \underbrace{E[N(t)]}_{=0} E[g^*V(t+\tau)]$$

$$+ \underbrace{E[g^*V(t)]}_{=0} \underbrace{E[N(t+\tau)]}_{=0}$$

$$+ \underbrace{E[N(t)N(t+\tau)]}_{R_N(\tau)}$$

Tenemos entonces :

$$R_V(\tau) = \mathbb{E}[(g * V(t+\tau))(g * V(t))] + R_N(\tau)$$

$$\begin{aligned} & \mathbb{E}[(g * V(t+\tau))(g * V(t))] \\ &= \mathbb{E}\left[\int g(u) V(t+\tau-u) du \int g(v) V(t-v) dv\right] \\ &= \iint g(u) g(v) \underbrace{\mathbb{E}[V(t+\tau-u-t+v)]}_{R_V(\tau-u+v)} du dv \\ &= \int g(v) \underbrace{\left\{ \int g(u) R_V(\tau+v-u) du \right\}}_{g * R_V(\tau+v)} dv \\ &= \int g(-z) (g * R_V(\tau-z)) dz \end{aligned}$$

$$z = -v$$

$$\approx \bar{g} * g * R_V(\tau)$$

$$\begin{aligned} \Rightarrow S_V(f) &= \hat{g}^*(f) \cdot \hat{g}(f) S_V(f) + S_N(f) \\ &= |\hat{g}(f)|^2 S_V(f) + S_N(f) \end{aligned}$$

Finalmente, obtener:

$$\hat{h}(f) = \frac{\hat{g}^*(f) S_v(f)}{|\hat{g}(f)|^2 S_v(f) + S_N(f)}$$