



# TRATAMIENTO DIGITAL DE SEÑALES

## Ingeniería de Telecomunicación (4º, 2º c)

Unidad 4ª: Los problemas generales gaussianos

Aníbal R. Figueiras Vidal

Jesús Cid Sueiro

Ángel Navia Vázquez

Área de Teoría de la Señal y Comunicaciones  
Universidad Carlos III de Madrid



### Ejercicio de Ampliación

A: Dos v. a. independientes,  $s: G(0, v_s)$  y  $r: G(0, v_r)$ , dan lugar a la observación:  
 $x = s+r$  (señal gaussiana en ruido gaussiano).

Determinése el estimador ms de  $s$ .

*Se está buscando  $\hat{s}_{ms} = E\{s | x\}$*

*y no se conoce directamente  $p(s | x)$ ; pero sí*

$$p(s): \quad G(0, v_s)$$

*y además*

$$p(x): \quad G(0, v_s + v_r)$$

$$p(x | s): \quad G(s, v_r)$$

*con lo que se puede determinar*

$$p(s | x) = \frac{p(x | s)p(s)}{p(x)}$$

*que será gaussiana, al serlo las demás:*



$$p(s/x) = \frac{1}{\sqrt{2\pi}} \frac{\frac{1}{\sqrt{v_r}} \frac{1}{\sqrt{v_s}}}{\frac{1}{\sqrt{v_s + v_r}}} \exp \left[ -\frac{1}{2} \left( \frac{(x-s)^2}{v_r} + \frac{s^2}{v_s} - \frac{x^2}{v_s + v_r} \right) \right]$$

*e identificando exponentes:*

$$\frac{(s - E\{s/x\})^2}{v_{s/x}} = \frac{(x-s)^2}{v_r} + \frac{s^2}{v_s} - \frac{x^2}{v_s + v_r}$$

- *términos en  $s^2$ :*

$$\frac{1}{v_{s/x}} = \frac{1}{v_r} + \frac{1}{v_s}; \quad v_{s/x} = \frac{v_s v_r}{v_s + v_r}$$

- *términos en  $-2s$ :*

$$\frac{E\{s/x\}}{v_{s/x}} = \frac{x}{v_r}; \quad E\{s/x\} = \frac{v_{s/x}}{v_r} x = \frac{v_s}{v_s + v_r} x$$

*(no es preciso seguir)*



*de modo que*

$$\hat{S}_{ms} = \frac{v_s}{v_s + v_r} x$$

*sobre lo que puede observarse que:*

- *es lineal*
- *atribuye a la señal una parte de la observación de acuerdo con los valores de potencia de señal y ruido.*

*Debe recordarse también que, dada la gaussianidad, el valor encontrado es también  $\hat{S}_{ma}$  y  $\hat{S}_{map}$ .*



### Ejercicio de Ampliación

A: El mismo problema en el caso multidimensional toma la forma general

$$\mathbf{x} = \mathbf{H}\mathbf{s} + \mathbf{r}$$

donde  $\mathbf{s}$  ( $N \times 1$ ) es  $G(\mathbf{0}, \mathbf{V}_s)$ ,  $\mathbf{r}$  ( $M \times 1$ ) es  $G(\mathbf{0}, \mathbf{V}_r)$ , y  $\mathbf{H}$  es una matriz  $M \times N$ , que se supondrá conocida.

Establecer  $\hat{\mathbf{s}}_{ms}$

Notando que

$$\mathbf{x}: G(\mathbf{0}, \mathbf{H}\mathbf{V}_s\mathbf{H}^T + \mathbf{V}_r)$$

$$\mathbf{x}/\mathbf{s}: G(\mathbf{H}\mathbf{s}, \mathbf{V}_r)$$

y procediendo, como en el ejercicio anterior, a identificar exponentes:

$$\begin{aligned} [\mathbf{s} - E\{\mathbf{s} / \mathbf{x}\}]^T \mathbf{V}_{s/x}^{-1} [\mathbf{s} - E\{\mathbf{s} / \mathbf{x}\}] &= \\ &= (\mathbf{x} - \mathbf{H}\mathbf{s})^T \mathbf{V}_r^{-1} (\mathbf{x} - \mathbf{H}\mathbf{s}) + \mathbf{s}^T \mathbf{V}_s^{-1} \mathbf{s} - \mathbf{x}^T (\mathbf{H}\mathbf{V}_s\mathbf{H}^T + \mathbf{V}_r)^{-1} \mathbf{x} \end{aligned}$$



- *términos cuadráticos:*

$$\mathbf{s}^T \mathbf{V}_{s/x}^{-1} \mathbf{s} = (\mathbf{H}\mathbf{s})^T \mathbf{V}_r^{-1} \mathbf{H}\mathbf{s} + \mathbf{s}^T \mathbf{V}_s^{-1} \mathbf{s}$$

de donde:  $\mathbf{V}_{s/x}^{-1} = \mathbf{H}^T \mathbf{V}_r^{-1} \mathbf{H} + \mathbf{V}_s^{-1}$

$$\mathbf{V}_{s/x} = (\mathbf{H}^T \mathbf{V}_r^{-1} \mathbf{H} + \mathbf{V}_s^{-1})^{-1}$$

- *términos lineales (sin -2):*

$$\mathbf{E}^T \{ \mathbf{s} / \mathbf{x} \} \mathbf{V}_{s/x}^{-1} = \mathbf{x}^T \mathbf{V}_r^{-1} \mathbf{H}$$

de donde:  $\mathbf{E}^T \{ \mathbf{s} / \mathbf{x} \} = \mathbf{x}^T \mathbf{V}_r^{-1} \mathbf{H} \mathbf{V}_{s/x}$

$$\mathbf{E} \{ \mathbf{s} / \mathbf{x} \} = \mathbf{V}_{s/x} \mathbf{H}^T \mathbf{V}_r^{-1} \mathbf{x}$$

y sustituyendo  $\mathbf{V}_{s/x}$ :

$$\hat{\mathbf{s}}_{ms} = (\mathbf{H}^T \mathbf{V}_r^{-1} \mathbf{H} + \mathbf{V}_s^{-1})^{-1} \mathbf{H}^T \mathbf{V}_r^{-1} \mathbf{x}$$

Puede notarse lo mismo que en el caso unidimensional: en particular, que el estimador es una arquitectura lineal (forma  $\mathbf{w}^T \mathbf{x}$ ).

Es claro que, si  $\mathbf{H}=\mathbf{I}$  (implica  $M=N$ ), la solución tiene el mismo sentido de “reparto” que el en caso unidimensional.



### Ejercicio

E: Analice y discuta el caso de  $(M)$  observaciones unidimensionales directas de variables independientes en ruido de valores independientes.

Se trata de un caso con  $\mathbf{H}=\mathbf{I}$

con matrices de autocovarianza diagonales:  $[\mathbf{D}_s]_{ii} = v_{si}$

$[\mathbf{D}_r]_{ii} = v_{ri}$

lo será  $\mathbf{V}_{s/x}$  :  $\mathbf{D}_{s/x} = (\mathbf{D}_{-s} + \mathbf{D}_{-r})^{-1}$

$$[\mathbf{D}_{s/x}]_{ii} = \left( \frac{1}{v_{si}} + \frac{1}{v_{ri}} \right)^{-1} = \frac{v_{si}v_{ri}}{v_{si} + v_{ri}}$$

con lo que

$$\hat{\mathbf{s}}_{ms} = \mathbf{D}_{s/x} \mathbf{D}_r^{-1} \mathbf{x}$$

tiene como elementos

$$\hat{s}_{msi} = \frac{v_{si}}{v_{si} + v_{ri}} x_i$$

como cabía esperar, extensión directa del caso unidimensional.



### Ejercicio

E: Analice y discuta el caso de  $(M)$  observaciones de la misma variable en ruido de valores independientes.

En este caso,  $\mathbf{H} = \mathbf{1} (M \times 1)$

$$\mathbf{V}_s = v_s$$

$$[\mathbf{D}_r]_{ii} = v_{ri}$$

$$\mathbf{V}_{s/x} = \left( \mathbf{1}^T \mathbf{D}_r^{-1} \mathbf{1} + v_s^{-1} \right)^{-1} = \frac{1}{v_s^{-1} + \sum_i v_{ri}^{-1}}$$

$$\hat{S}_{ms} = \frac{1}{v_s^{-1} + \sum_i v_{ri}^{-1}} \mathbf{1}^T \mathbf{D}_r^{-1} \mathbf{x} = \frac{1}{v_s^{-1} + \sum_i v_{ri}^{-1}} \sum_i v_{ri}^{-1} x_i$$

que es una media muestral ponderada; si los ruidos son i. d.,  $v_{ri} = v_r$

$$\hat{S}_{ms} = \frac{1}{v_s^{-1} + M v_r^{-1}} v_r^{-1} \sum_i x_i = \frac{1}{M + v_r v_s^{-1}} \sum_i x_i$$

que es una media muestral modificada (según potencias: teniendo en cuenta la coherencia de la señal y la incoherencia del ruido).





### Ejercicio de Ampliación

A: La forma general del problema de decidir entre dos señales deterministas (conocidas) en presencia de ruido gaussiano (conocido) es

$$H_0: \mathbf{x} = \mathbf{m}_0 + \mathbf{n}_0$$

$$H_1: \mathbf{x} = \mathbf{m}_1 + \mathbf{n}_1$$

con los ruidos  $\mathbf{n}_i : G(\mathbf{0}, \mathbf{V}_i)$

Formule el correspondiente LRT.

Recordando que 
$$p(\mathbf{x} / H_i) = \frac{1}{(2\pi)^{N/2} |\mathbf{V}_i|^{1/2}} \exp\left[-\frac{1}{2}(\mathbf{x} - \mathbf{m}_i)^T \mathbf{V}_i^{-1}(\mathbf{x} - \mathbf{m}_i)\right]$$

tomando neperianos y eliminando términos comunes

$$\ln \frac{p(\mathbf{x} / H_1)}{p(\mathbf{x} / H_0)} = \ln \left( \frac{|\mathbf{V}_0|}{|\mathbf{V}_1|} \right)^{1/2} - \frac{1}{2} \left[ (\mathbf{x} - \mathbf{m}_1)^T \mathbf{V}_1^{-1}(\mathbf{x} - \mathbf{m}_1) - (\mathbf{x} - \mathbf{m}_0)^T \mathbf{V}_0^{-1}(\mathbf{x} - \mathbf{m}_0) \right] \stackrel{D_1}{\underset{D_0}{\gtrless}}$$

$$\stackrel{D_1}{\underset{D_0}{\gtrless}} \ln \frac{(C_{10} - C_{00}) Pr(H_0)}{(C_{01} - C_{11}) Pr(H_1)} = \ln \eta$$



que se puede reescribir

$$(\mathbf{x} - \mathbf{m}_0)^T \mathbf{V}_0^{-1} (\mathbf{x} - \mathbf{m}_0) - (\mathbf{x} - \mathbf{m}_1)^T \mathbf{V}_1^{-1} (\mathbf{x} - \mathbf{m}_1) \stackrel{D_1}{\underset{D_0}{\gtrless}} 2 \ln \eta - \ln \frac{|\mathbf{V}_0|}{|\mathbf{V}_1|} = \eta_1$$

que supone una frontera (general) **cuadrática** (e igual tipo de **discriminantes**).

Las formas ponderadas  $(\mathbf{x} - \mathbf{m}_i)^T \mathbf{V}_i^{-1} (\mathbf{x} - \mathbf{m}_i)$ , obviamente generalizaciones de los (cuadrados de) las distancias euclídeas entre  $\mathbf{x}$  y  $\mathbf{m}_i$ , se denominan **distancias de Mahalanobis**: la decisión se realiza en función de ellas.



Ejercicio de Ampliación

A: Analice y discuta el problema anterior si el ruido no depende de la señal presente.

Será  $V_1 = V_0 = V$ ; operando, desaparecen los términos cuadráticos y queda

$$-2\mathbf{m}_0^T V^{-1} \mathbf{x} + \mathbf{m}_0^T V^{-1} \mathbf{m}_0 + 2\mathbf{m}_1^T V^{-1} \mathbf{x} - \mathbf{m}_1^T V^{-1} \mathbf{m}_1 \underset{D_0}{\overset{D_1}{\gtrless}} \eta_1$$

$$(\mathbf{m}_1 - \mathbf{m}_0)^T V^{-1} \mathbf{x} \underset{D_0}{\overset{D_1}{\gtrless}} \frac{1}{2} (\eta_1 + \mathbf{m}_1^T V^{-1} \mathbf{m}_1 - \mathbf{m}_0^T V^{-1} \mathbf{m}_0) = \eta_2$$


que es un decisor lineal  $\mathbf{w}^T \mathbf{x} \underset{D_0}{\overset{D_1}{\gtrless}} \eta_2$

Si además las componentes del ruido son iid:  $V = v\mathbf{I}$


$$(\mathbf{m}_1 - \mathbf{m}_0)^T v^{-1} \mathbf{I} \mathbf{x} \underset{D_0}{\overset{D_1}{\gtrless}} \eta_2$$

$$(\mathbf{m}_1 - \mathbf{m}_0)^T \mathbf{x} \underset{D_0}{\overset{D_1}{\gtrless}} v \eta_2 = \eta_3 \quad \left( = \frac{1}{2} [2v \ln \eta + \|\mathbf{m}_1\|_2^2 - \|\mathbf{m}_0\|_2^2] \right)$$

que, como se sabe, es realizable como “decisor de correlación”



o “de filtro adaptado”



Si, además  $\mathbf{m}_0 = \mathbf{0}$  (detección de  $\mathbf{m}_1$ ): desaparecen las ramas correspondientes; el umbral pasa a  $\eta_4 = \frac{1}{2} \left( 2\nu \ln \eta + \|\mathbf{m}_1\|_2^2 \right)$   
 (en caso ML, queda  $\frac{1}{2} \|\mathbf{m}_1\|_2^2$  : se pide que  $\mathbf{m}_1^T \mathbf{x}$  llegue a la mitad de energía de  $\mathbf{m}_1$ ).



### Ejercicio de Ampliación

A: Analice y discuta la decisión (binaria) gaussiana cuando se trata de la misma señal en distintos ruidos.

$m_1 = m_0 = m$ : siguen empleándose las distancias de Mahalanobis

$$(x - m)^T (V_0^{-1} - V_1^{-1}) (x - m) \stackrel{D_1}{\geq} \stackrel{D_0}{\eta_1}$$

- Si además, los ruidos son iid:  $V_i = v_i I$

$$(x - m)^T \begin{pmatrix} \frac{1}{v_0} & \\ & \frac{1}{v_1} \end{pmatrix} I (x - m)$$

admitiendo  $v_1 > v_0$  (si no, voltean las desigualdades)

$$\|x - m\|_2^2 \stackrel{D_1}{\geq} \stackrel{D_0}{\frac{v_0 v_1}{v_1 - v_0}} \eta_1$$

decisor por distancia euclídea

- Si además  $m = 0$  :  $\|x\|_2^2 \stackrel{D_1}{\geq} \stackrel{D_0}{\frac{v_0 v_1}{v_1 - v_0}} \eta_1$

que decide por energía entre las dos opciones de varianza del ruido.



### Estadísticos suficientes

Se han visto casos en los que no es preciso el conocimiento del conjunto de las observaciones (o de las variables) para realizar la estimación o la decisión:

- estimar  $m$  y  $v$  de una gaussiana requiere sólo  $\sum_k x^{(k)}$ ,  $\sum_k x^{(k)2}$
- estimar una gaussiana en otra gaussiana requiere formas del tipo  $\mathbf{w}^T \mathbf{x}$ :  
lineales también
- decidir qué señal determinista es la que se encuentra en ruido gaussiano requiere formas cuadráticas (o lineales)

Estas formas se llaman **estadísticos suficientes**: conocerlos permite simplificar procesos de estimación o decisión.



### Teorema de Factorización

El resultado de una transformación de las observaciones  $\mathbf{t} = \mathbf{t}(\mathbf{x})$  es un estadístico suficiente para estimar (ML) el parámetro determinista  $\mathbf{s}$  si y sólo si

$$p(\mathbf{x} | \mathbf{s}) = g(\mathbf{t}, \mathbf{s}) h(\mathbf{x}, \mathbf{t})$$

(La descomposición no es única:  $g'(\mathbf{t}, \mathbf{s}) = g(\mathbf{t}, \mathbf{s}) f(\mathbf{t})$   
 $h'(\mathbf{x}, \mathbf{t}) = h(\mathbf{x}, \mathbf{t}) / f(\mathbf{t})$  )

ya que

$$\arg[\max_{\mathbf{s}} p(\mathbf{x} | \mathbf{s})] = \arg[\max_{\mathbf{s}} g(\mathbf{t}, \mathbf{s})]$$

(y se comprende fácilmente la ventaja si  $g$  es sencilla); y no ocurre en otro caso.



Una formulación equivalente es:

$$p(\mathbf{x} | \mathbf{s}, \mathbf{t}) = p(\mathbf{x} | \mathbf{t})$$

Suficiente: si se da la equivalente,

$$p(\mathbf{x} | \mathbf{s}) = p(\mathbf{x} | \mathbf{s}, \mathbf{t}) p(\mathbf{t} | \mathbf{s}) = p(\mathbf{x} | \mathbf{t}) p(\mathbf{t} | \mathbf{s})$$

y se pueden identificar los factores con  $h$  y  $g$ , respectivamente.

Necesaria: suponemos que se cumple el Teorema de Factorización; como

$$p(\mathbf{x} | \mathbf{s}, \mathbf{t}) = \frac{p(\mathbf{x}, \mathbf{t} | \mathbf{s})}{p(\mathbf{t} | \mathbf{s})} = \frac{p(\mathbf{x}, \mathbf{t} | \mathbf{s})}{\int p(\mathbf{x}, \mathbf{t} | \mathbf{s}) d\mathbf{x}}$$

y como  $p(\mathbf{x}, \mathbf{t} | \mathbf{s})$  es  $p(\mathbf{x} | \mathbf{s})$ , al ser  $\mathbf{t}$  una función de  $\mathbf{x}$ , se tiene





$$p(\mathbf{x} | \mathbf{s}, \mathbf{t}) = \frac{p(\mathbf{x} | \mathbf{s})}{\int p(\mathbf{x} | \mathbf{s}) d\mathbf{x}}$$

aplicando el Teorema de Factorización

$$p(\mathbf{x} | \mathbf{s}, \mathbf{t}) = \frac{g(\mathbf{t}, \mathbf{s}) h(\mathbf{x}, \mathbf{t})}{\int g(\mathbf{t}, \mathbf{s}) h(\mathbf{x}, \mathbf{t}) d\mathbf{x}} = \frac{h(\mathbf{x}, \mathbf{t})}{\int h(\mathbf{x}, \mathbf{t}) d\mathbf{x}}$$

que no depende de  $\mathbf{s}$ , y que, por identificación, resulta ser  $p(\mathbf{x} | \mathbf{t})$ .

---

En ocasiones  $\mathbf{t}$  se obtiene de una transformación uno a uno de los datos:  
 $\mathbf{x} \rightarrow \mathbf{t}, \mathbf{i}$ ; el conjunto  $\mathbf{i}$  es un **estadístico irrelevante**.



### Caso de estimación de parámetro aleatorio

Sigue siendo válido el Teorema de Factorización, ya que de  $p(\mathbf{x} | \mathbf{s}, \mathbf{t}) = p(\mathbf{x} | \mathbf{t})$  se sigue

$$p(\mathbf{s} | \mathbf{x}) = p(\mathbf{s} | \mathbf{x}, \mathbf{t}) = \frac{p(\mathbf{s}, \mathbf{x} | \mathbf{t})}{p(\mathbf{x} | \mathbf{t})} = \frac{p(\mathbf{x} | \mathbf{s}, \mathbf{t})p(\mathbf{s} | \mathbf{t})}{p(\mathbf{x} | \mathbf{t})} = p(\mathbf{s} | \mathbf{t})$$

lo que indica claramente que, dado  $\mathbf{t}$ , los datos originales no se necesitan para realizar cualquier estimación Bayesiana

$$\min_{\hat{\mathbf{s}}} \int C(\mathbf{s}, \hat{\mathbf{s}}) p(\mathbf{s} | \mathbf{x}) d\mathbf{s}$$



### Caso de decisión

Es obvio que la condición equivalente es

$$p(\mathbf{x} | H_i) = g(\mathbf{t}, H_i) h(\mathbf{x}, \mathbf{t})$$

o también

$$\Pr(H_i | \mathbf{x}) (= \Pr(H_i | \mathbf{x}, \mathbf{t})) = \Pr(H_i | \mathbf{t})$$

ya que basta  $g(\mathbf{t}, H_i)$  o  $\Pr(H_i | \mathbf{t})$  para la decisión Bayesiana.



### Ejercicio

E: Determinar un estadístico suficiente para la estimación del parámetro de una distribución exponencial unilateral (Maxwell),  $p(x) = a \exp(-ax) u(x)$  ( $a > 0$ ), mediante  $K$  observaciones independientes.

$$p(\mathbf{x} | a) = \prod_{k=1}^K a \exp(-ax^{(k)}), \quad \{\mathbf{x}\} \geq 0$$

$$\ln p(\mathbf{x} | a) = \sum_{k=1}^K [\ln a - ax^{(k)}] = K \ln a - a \sum_{k=1}^K x^{(k)}$$

y ya se observa que  $\sum_{k=1}^K x^{(k)}$  es un estadístico suficiente...

$$\frac{\partial \ln}{\partial a} = \frac{K}{a} - \sum_{k=1}^K x^{(k)}; \quad \left. \frac{\partial \ln}{\partial a} \right|_{a=\hat{a}_{ml}} = 0 = \frac{K}{\hat{a}_{ml}} - \sum_{k=1}^K x^{(k)} \quad \left( \frac{\partial^2 \ln}{\partial a^2} = -\frac{K}{a^2} < 0 \right)$$

$$\hat{a}_{ml} = \frac{K}{\sum_{k=1}^K x^{(k)}}$$



*Obsérvese que en este caso la propia  $p(\mathbf{x} | a)$  tiene la forma de  $g(t, a)$ , con*

$$t = \sum_{k=1}^K x^{(k)}$$

*lo que se ve claramente en las expresiones que resultan de tomar logaritmos (en que la factorización se convierte en separación de sumandos):*

$$\ln p(\mathbf{x} | a) = K \ln a - a \sum_{k=1}^K x^{(k)} = K \ln a - at \quad (= g(t, a))$$