

FILTRADO LINEAL OPTIMO: FILTRO DE WIENER

TRATAMIENTO AVANZADO DE SEÑAL EN COMUNICACIONES

Grupo de Tratamiento Avanzado de Señal (GTAS)


Dpto. de Ingeniería de Comunicaciones (DICOM), Universidad de Cantabria



Índice

- Derivación del filtro de Wiener.
- Un primer ejemplo en comunicaciones: Igualación.
- Cálculo teórico y estima del filtro de Wiener en Matlab.
- Principio de ortogonalidad.
- Superficie de error. Propiedades.
- Extensiones: IIR causal y no causal, complejo.
- Filtrado óptimo con restricciones: "LCMV beamformer", ejemplos.
- Filtro adaptado estocástico ("eigenfilter").
- Conclusiones.

Planteamiento del problema: CASO FIR



- Entrada: $\mathbf{x}_n = [x(n), x(n-1), \dots, x(n-M+1)]^T$
- Coeficientes: $\mathbf{w} = [w_0, w_1, \dots, w_{M-1}]^T$
- Salida:
$$y(n) = \sum_{i=0}^{M-1} x(n-i)w_i = \mathbf{x}_n^T \mathbf{w} = \mathbf{w}^T \mathbf{x}_n$$

Función de coste I

- Error: $e(n) = d(n) - y(n) = d(n) - \mathbf{x}_n^T \mathbf{w}$
- La estima de mínimo error cuadrático medio (MMSE), es la solución que minimiza

$$J(\mathbf{w}) = E[e^2(n)]$$

- Desarrollando la función de coste se obtiene

$$J(\mathbf{w}) = E[d^2(n) + \mathbf{w}^T \mathbf{x}_n \mathbf{x}_n^T \mathbf{w} - 2d(n) \mathbf{w}^T \mathbf{x}_n]$$

$$J(\mathbf{w}) = E[d^2(n)] + \mathbf{w}^T E[\mathbf{x}_n \mathbf{x}_n^T] \mathbf{w} - 2\mathbf{w}^T E[d(n) \mathbf{x}_n] = \sigma_d^2 + \mathbf{w}^T \mathbf{R}_x \mathbf{w} - 2\mathbf{w}^T \mathbf{p}$$

Función de coste II

- Siendo \mathbf{R}_x la matriz de autocorrelación de la entrada

$$\mathbf{R}_x = E[\mathbf{x}_n \mathbf{x}_n^T] = \begin{bmatrix} E[x(n)x(n)] & E[x(n)x(n-1)] & \dots & E[x(n)x(n-M+1)] \\ E[x(n-1)x(n)] & \vdots & \vdots & E[x(n-1)x(n-M+1)] \\ \vdots & \ddots & \ddots & \vdots \\ E[x(n-M+1)x(n)] & \dots & \dots & E[x(n-M+1)x(n-M+1)] \end{bmatrix}$$

$$\mathbf{R}_x = \begin{bmatrix} R_x(0) & R_x(1) & \dots & R_x(M-1) \\ R_x(1) & R_x(0) & \vdots & R_x(M-2) \\ \vdots & \ddots & \ddots & \vdots \\ R_x(M-1) & R_x(M-2) & \dots & R_x(0) \end{bmatrix}_{M \times M}$$

MATRIZ TOEPLITZ

M es la longitud del filtro FIR

Hemos tenido en cuenta que $R_x(k) = R_x(-k)$

Función de coste III

- \mathbf{p} es el vector de correlación cruzada entre la entrada y la salida deseada

$$\mathbf{p} = E[d(n)\mathbf{x}_n] = \begin{bmatrix} E[d(n)x(n)] \\ E[d(n)x(n-1)] \\ \vdots \\ E[d(n)x(n-M+1)] \end{bmatrix}$$

- Por ejemplo, para un filtro con dos coeficientes, la función de coste sería

$$J(\mathbf{w}) = \sigma_d^2 + \begin{pmatrix} w_0 & w_1 \end{pmatrix} \begin{pmatrix} R_x(0) & R_x(1) \\ R_x(1) & R_x(0) \end{pmatrix} \begin{pmatrix} w_0 \\ w_1 \end{pmatrix} - 2 \begin{pmatrix} w_0 & w_1 \end{pmatrix} \begin{pmatrix} p(0) \\ p(-1) \end{pmatrix}$$

$$J(\mathbf{w}) = \sigma_d^2 + (w_0^2 + w_1^2)R_x(0) + 2w_0w_1R_x(1) - 2w_0p(0) - 2w_1p(-1)$$

Filtro de Wiener

- La función de coste es cuadrática en los coeficientes del filtro

↓
Solución única (filtro de Wiener)

$$\nabla_{\mathbf{w}} J(\mathbf{w}) = \left[\frac{\partial J}{\partial w_0} \quad \frac{\partial J}{\partial w_1} \quad \dots \quad \frac{\partial J}{\partial w_{M-1}} \right]^T = \frac{\partial(\sigma_d^2 + \mathbf{w}^T \mathbf{R}_x \mathbf{w} - 2\mathbf{w}^T \mathbf{p})}{\partial \mathbf{w}} = 2\mathbf{R}_x \mathbf{w} - 2\mathbf{p} = 0$$

Ec's normales: $\mathbf{R}_x \mathbf{w} = \mathbf{p}$



$$\mathbf{w}_{opt} = \mathbf{R}_x^{-1} \mathbf{p}$$


¿Qué pasa si \mathbf{R}_x es singular?

- Sustituyendo la solución en la función de coste se obtiene el error cuadrático medio mínimo

$$J(\mathbf{w}_{opt}) = \sigma_d^2 - \mathbf{p}^T \mathbf{w}_{opt}$$

Ejemplo 1

- Igualación de un canal de comunicaciones digitales



- Para resolver teóricamente el filtro de Wiener son necesarios los estadísticos de segundo orden del problema, en concreto hay que conocer:
 - 1.- Modelo estadístico de la señal de entrada: i.i.d BSPK $\{-1,+1\}$.
 - 2.- Modelo estadístico del ruido: AWGN de media cero y varianza σ_r^2 .
 - 3.- El canal h .

Ejemplo 1

- Para el modelo considerado:

$$R_x(k) = R_{hh}(k) + \sigma_r^2 \delta(k) \quad \text{con} \quad R_{hh}(k) = h(k) * h(-k)$$

$$\begin{aligned} p(-k) &= E[s(n-d)x(n-k)] = \\ &= E\left[s(n-d) \left(\sum_r h(r)s(n-k-r) + r(n-k) \right) \right] = h(d-k) \end{aligned}$$

- Ecuaciones normales:

$$\begin{bmatrix} R_{hh}(0) + \sigma_r^2 & R_{hh}(1) & \dots & R_{hh}(M-1) \\ R_{hh}(1) & R_{hh}(0) + \sigma_r^2 & \vdots & R_x(M-2) \\ \vdots & \ddots & \ddots & \vdots \\ R_{hh}(M-1) & R_{hh}(M-2) & \dots & R_{hh}(0) + \sigma_r^2 \end{bmatrix} \begin{bmatrix} w_0 \\ w_1 \\ \vdots \\ w_{M-1} \end{bmatrix} = \begin{bmatrix} h(d) \\ h(d-1) \\ \vdots \\ h(d-M+1) \end{bmatrix}$$

Ejemplo 1


- Fichero: Wiener_eq.m

$$h = [0.3 \quad -0.7 \quad 0.6 \quad 0.2]$$

$$SNR = 20 \text{ dB}$$

$$M = 15$$

$$d = 7$$



Ejemplo 1

- Fichero: Wiener_eq.m


$$h = [0.3 \quad -0.7 \quad 0.6 \quad 0.2]$$

$$SNR = 20 \text{ dB}$$

$$M = 15$$


$$d = 0$$

Wiener filter (blue), original BPSK (red)




¿Por qué es necesario un retardo?


- Suponemos una situación sin ruido y un canal causal y estable.
- Si el canal es de fase no mínima (alguno de sus ceros fuera del círculo unidad) el inverso estable es no causal.



- Si no incluimos un retardo, la aproximación del filtro de Wiener al inverso del canal será muy mala:




- Si permitimos un cierto retardo:



Estima del filtro de Wiener I

- En un caso práctico no se conoce el canal ni la varianza de ruido, tan sólo se conoce la señal deseada $s(n)$, en un intervalo $n=1, \dots, N$. (Secuencia de entrenamiento).
- Por ejemplo, en GSM



$$R_b = 270.833 \text{ kb/s}$$

Hay 26 símbolos conocidos por el receptor

Estima del filtro de Wiener II

- La matriz de autocorrelación se estima como $\hat{\mathbf{R}}_x = \frac{1}{N} \sum_{n=1}^N \mathbf{x}_n \mathbf{x}_n^T$
- La correlación cruzada $\hat{\mathbf{p}} = \frac{1}{N} \sum_{n=1}^N s(n) \mathbf{x}_n$
- Si queremos incluir un retardo d

$$\hat{\mathbf{p}} = \frac{1}{N} \sum_{n=1}^N s(n) \mathbf{x}_{n+d}$$

$$\hat{\mathbf{R}}_x = \frac{1}{N} \sum_{n=1}^N \mathbf{x}_{n+d} \mathbf{x}_{n+d}^T$$

- El igualador óptimo bajo un criterio MMSE es

$$\hat{\mathbf{w}}_{opt} = \hat{\mathbf{R}}_x^{-1} \hat{\mathbf{p}}$$

“Direct Matrix Inversion” (DMI)

Ejemplo 2

Fase mínima

- Fichero: Wiener_eq_est.m

$$h = [1 \quad -0.3 \quad 0.6] \quad SNR = 25 \text{ dB}$$

$$M = 5 \quad d = 0 \quad N = 50$$

$$\mathbf{R}_x = \begin{bmatrix} 1.4546 & -0.4800 & 0.6000 & 0 & 0 \\ -0.4800 & 1.4546 & -0.4800 & 0.60 & 0 \\ 0.6000 & -0.4800 & 1.4546 & -0.48 & 0.6 \\ 0 & 0.6000 & -0.4800 & 1.4546 & -0.4800 \\ 0 & 0 & 0.6000 & -0.4800 & 1.4546 \end{bmatrix}$$

$$\mathbf{p} = \begin{bmatrix} 1 \\ 0 \\ 0 \\ 0 \\ 0 \end{bmatrix}$$

$$\mathbf{w}_{opt} = \begin{bmatrix} 0.9452 \\ 0.2623 \\ -0.4150 \\ -0.2117 \\ 0.1013 \end{bmatrix}$$


$$\hat{\mathbf{R}}_x = \begin{bmatrix} 1.4734 & -0.5413 & 0.5827 & -0.0655 & -0.0346 \\ -0.5413 & 1.4650 & -0.5400 & 0.6066 & -0.0770 \\ 0.5827 & -0.5400 & 1.4738 & -0.5518 & 0.5925 \\ -0.0655 & 0.6066 & -0.5518 & 1.4132 & -0.5050 \\ -0.0346 & -0.0770 & 0.5925 & -0.5050 & 1.4253 \end{bmatrix}$$

$$\hat{\mathbf{p}} = \begin{bmatrix} 1.0065 \\ -0.0415 \\ -0.0430 \\ -0.0188 \\ -0.0508 \end{bmatrix}$$

$$\hat{\mathbf{w}}_{opt} = \begin{bmatrix} 0.9380 \\ 0.2521 \\ -0.4275 \\ -0.2074 \\ 0.1050 \end{bmatrix}$$

Ejemplo 2

teórico (azul), estimado (rojo)



Principio de ortogonalidad I


- El filtro de Wiener se puede también derivar a partir del principio de ortogonalidad: EL ERROR ES ORTOGONAL A LOS DATOS.

$$E[e(n)\mathbf{x}_n] = E[\mathbf{x}_n(d(n) - \mathbf{x}_n^T \mathbf{w})] = 0$$

$$\begin{array}{ccc} E[\mathbf{x}_n d(n)] = E[\mathbf{x}_n \mathbf{x}_n^T] \mathbf{w} & \left. \vphantom{E[\mathbf{x}_n d(n)]} \right\} & \longrightarrow \mathbf{w}_{opt} = \mathbf{R}_x^{-1} \mathbf{p} \\ \downarrow & & \\ \mathbf{p} & & \\ \downarrow & & \\ \mathbf{R}_x & & \end{array}$$

Principio de ortogonalidad II

- Interpretación geométrica



- Corolario: el error es ortogonal a la salida estimada

$$E[e(n)\mathbf{w}^T \mathbf{x}_n] = \mathbf{w}^T E[e(n)\mathbf{x}_n] = 0$$



Superficie de error I

- La función de coste es un paraboloide con un único mínimo

$$J(\mathbf{w}) = \sigma_d^2 + \mathbf{w}^T \mathbf{R}_x \mathbf{w} - 2\mathbf{w}^T \mathbf{p}$$

- Si consideramos un filtro de 2 coeficientes

$$J(\mathbf{w}) = \sigma_d^2 + \begin{pmatrix} w_0 & w_1 \end{pmatrix} \begin{pmatrix} 1 & r \\ r & 1 \end{pmatrix} \begin{pmatrix} w_0 \\ w_1 \end{pmatrix} - 2 \begin{pmatrix} w_0 & w_1 \end{pmatrix} \begin{pmatrix} p(0) \\ p(-1) \end{pmatrix}$$



Superficie de error II

- El eje del paraboloide es perpendicular al plano $J(\mathbf{w})=\text{cte.}$
- El mínimo está en $\mathbf{w}_{opt} = \mathbf{R}_x^{-1} \mathbf{p}$
- Su orientación y forma dependen exclusivamente de \mathbf{R}_x
- La función de coste puede escribirse como


$$J = J_{\min} + (\mathbf{w} - \mathbf{w}_{opt})^T \mathbf{R} (\mathbf{w} - \mathbf{w}_{opt})$$

$$J = J_{\min} + \tilde{\mathbf{w}}^T \mathbf{R}_x \tilde{\mathbf{w}} \quad \text{siendo} \quad \tilde{\mathbf{w}} = \mathbf{w} - \mathbf{w}_{opt}$$


Superficie canónica I

- $\tilde{\mathbf{w}} = \mathbf{w} - \mathbf{w}_{opt}$ define una traslación: el mínimo de la función de coste está ahora en $\tilde{\mathbf{w}}_{opt} = 0$

$J(\mathbf{w})$



$J(\tilde{\mathbf{w}})$



Superficie canónica II

- La matriz de autocorrelación puede escribirse en términos de sus autovectores y autovalores como

$$\mathbf{R}_x = \mathbf{Q}\mathbf{\Lambda}\mathbf{Q}^T = [\mathbf{q}_1 \quad \dots \quad \mathbf{q}_M] \begin{bmatrix} \lambda_1 & 0 & \dots & 0 \\ 0 & \lambda_2 & \dots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ 0 & \dots & 0 & \lambda_M \end{bmatrix} \begin{bmatrix} \mathbf{q}_1^T \\ \vdots \\ \mathbf{q}_M^T \end{bmatrix} = \sum_{i=1}^M \lambda_i \mathbf{q}_i \mathbf{q}_i^T$$

$$J = J_{\min} + \tilde{\mathbf{w}}^T \mathbf{Q}\mathbf{\Lambda}\mathbf{Q}^T \tilde{\mathbf{w}}$$


- Definimos ahora los vectores transformados (linealmente)

$$\mathbf{v} = \mathbf{Q}^T \tilde{\mathbf{w}}$$


Superficie canónica III

- Se obtiene así la forma o superficie canónica

$$J = J_{\min} + \mathbf{v}^T \Lambda \mathbf{v} = \sum_{i=1}^M \lambda_k |v_k|^2$$



$$\mathbf{v} = \mathbf{Q}^T \tilde{\mathbf{w}}$$

- Las direcciones en el espacio transformado (canónico) están alineadas con las direcciones principales del paraboloid.
- La excentricidad depende de los autovalores.

Un ejemplo

- Matriz de autocorrelación $\mathbf{R}_x = \begin{pmatrix} 2 & 1 \\ 1 & 2 \end{pmatrix}$
- Autovalores y autovectores


$$|\mathbf{R}_x - \lambda \mathbf{I}| = 0 \Rightarrow \begin{cases} \lambda_1 = 1 \Rightarrow \mathbf{v}_1 = \frac{1}{\sqrt{2}} \begin{pmatrix} 1 & -1 \end{pmatrix} \\ \lambda_2 = 3 \Rightarrow \mathbf{v}_2 = \frac{1}{\sqrt{2}} \begin{pmatrix} 1 & 1 \end{pmatrix} \end{cases}$$

$$\mathbf{R}_x = \mathbf{Q} \mathbf{\Lambda} \mathbf{Q}^T = \frac{1}{2} \begin{pmatrix} 1 & 1 \\ -1 & 1 \end{pmatrix} \begin{pmatrix} 1 & 0 \\ 0 & 3 \end{pmatrix} \begin{pmatrix} 1 & -1 \\ 1 & 1 \end{pmatrix}$$

Superficie de error:

$$J(\tilde{\mathbf{w}}) = J_{\min} + \begin{pmatrix} \tilde{w}_0 & \tilde{w}_1 \end{pmatrix} \begin{pmatrix} 2 & 1 \\ 1 & 2 \end{pmatrix} \begin{pmatrix} \tilde{w}_0 \\ \tilde{w}_1 \end{pmatrix} =$$
$$= 2\tilde{w}_0^2 + 2\tilde{w}_0\tilde{w}_1 + 2\tilde{w}_1^2$$


Variables acopladas



Superficie canónica:




$$J(\mathbf{v}) = J_{\min} + \begin{pmatrix} v_0 & v_1 \end{pmatrix} \begin{pmatrix} 1 & 0 \\ 0 & 3 \end{pmatrix} \begin{pmatrix} v_0 \\ v_1 \end{pmatrix} = v_0^2 + 3v_1^2$$

Variables desacopladas



Caso general

- Matriz de autocorrelación $R_x = \begin{pmatrix} \sigma^2 & r\sigma^2 \\ r\sigma^2 & \sigma^2 \end{pmatrix} \Rightarrow \Lambda = \begin{pmatrix} (1+r)\sigma^2 & 0 \\ 0 & (1-r)\sigma^2 \end{pmatrix}$
siendo $r = \frac{R_x(1)}{R_x(0)}$ el coeficiente de correlación.



- Dispersión de autovalores: $\frac{\lambda_{max}}{\lambda_{min}} = \frac{1+r}{1-r}$
- Un valor alto indica mal condicionamiento de la matriz de autocorrelación.

Estimación lineal vs. no lineal

- Hemos visto hasta ahora que el filtro de Wiener es el estimador LINEAL que minimiza el MSE

$$\hat{d}(n) = \mathbf{w}_{opt}^T \mathbf{x}_n \quad \text{con} \quad \mathbf{w}_{opt} = \mathbf{R}_x^{-1} \mathbf{p}$$


Es necesario conocer los estadísticos de segundo orden.

- El estimador que minimiza el MSE es, en general, no lineal y se obtiene como

$$\hat{d}(n) = E[d(n) | \mathbf{x}_n]$$

Es necesario conocer: $f_{d|x_n}(d(n) | \mathbf{x}_n)$

Estimación lineal vs. no lineal: ejemplo




Algunas extensiones

- Hasta ahora nos hemos concentrado en el caso del filtrado óptimo FIR con secuencias reales.
- A continuación extendemos las ideas expuestas sobre filtrado óptimo a:

- 
- 1.- Filtros IIR (no causales)
 - 2.- Filtro IIR (causales)
 - 3.- Filtros FIR complejos

Filtro de Wiener IIR



- La salida del filtro IIR es $y(n) = \sum_{k=-\infty}^{\infty} w_k x(n-k)$
- El principio de ortogonalidad sigue siendo válido

$$\min E [e^2(n)] \Rightarrow E[e(n)x(n-l)] = 0 \quad -\infty < l < \infty$$


Ec's Normales: $\sum_{k=-\infty}^{\infty} w_k R_{xx}(l-k) = p(l) \quad -\infty < l < \infty$

Filtro de Wiener IIR

- Es posible escribir la solución en el dominio de la frecuencia:

$$W(\omega) = \frac{S_{xd}(\omega)}{S_{xx}(\omega)}$$

- Para el problema de igualación/deconvolución visto anteriormente



$$W(\omega) = \frac{S_{xd}(\omega)}{S_{xx}(\omega)} = \frac{H(\omega)^*}{|H(\omega)|^2 + \sigma_r^2}$$

- Si no hay ruido:
$$W(\omega) = \frac{S_{xd}(\omega)}{S_{xx}(\omega)} = \frac{H(\omega)^*}{|H(\omega)|^2} = \frac{1}{H(\omega)}$$

El filtro de Wiener es el filtro inverso (en general, IIR no causal)

Filtro de Wiener IIR (causal)

- Es posible también obtener el filtro óptimo IIR causal

$$\sum_{k=0}^{\infty} w_k R_x(l-k) = p(l) \quad l \geq 0$$

- La solución de este problema es algo más complicada

$$S_{xx}(z) = \sigma_x^2 Q(z)Q(z^{-1}) \quad Q(z) \quad \text{es fase mínima}$$

- Entonces:

$$W(z) = \left[\frac{S_{xd}(z)}{Q(z^{-1})} \right]_+ \frac{1}{\sigma_x^2 Q(z)}$$



Parte causal

Filtro de Wiener complejo

- En el caso de secuencias complejas (filtro FIR)

$$y(n) = \sum_{i=0}^{M-1} x(n-i)w_i^* = \mathbf{w}^H \mathbf{x}_n$$

H denota hermítico (conjugado y transpuesto)

- La solución del filtro óptimo sigue siendo

$$\mathbf{w}_{opt} = \mathbf{R}_x^{-1} \mathbf{p}$$

pero ahora $\mathbf{R}_x = E[\mathbf{x}_n \mathbf{x}_n^H]$


$$\mathbf{p} = E[\mathbf{x}_n d^*(n)]$$

$$\hat{\mathbf{R}}_x = \frac{1}{N} \sum_{n=1}^N \mathbf{x}_n \mathbf{x}_n^H$$

$$\hat{\mathbf{p}} = \frac{1}{N} \sum_{n=1}^N \mathbf{x}_n d^*(n)$$

Filtrado lineal óptimo con restricciones

- En ciertos problemas de comunicaciones, por ejemplo en conformación de haz ("beamforming"), es necesario minimizar el MSE sujeto a un restricción lineal.




minimizar

$$E[|y(n)|^2] = \mathbf{w}^H \mathbf{R}_x \mathbf{w}$$

s.t.

$$\mathbf{w}^H \mathbf{s}(\theta_0) = g$$

Modelo de propagación



El retardo entre dos elementos del array es $\tau(\theta) = \frac{d \text{sen}(\theta)}{c}$

Hipótesis: onda plana, banda estrecha, array equiespaciado:

$$s_0(t) = u(t)e^{j\omega_0 t} \Rightarrow s_1(t) = u(t - \tau(\theta))e^{j\omega_0 t} e^{-j\omega_0 \tau(\theta)} \approx u(t)e^{j\omega_0 t} e^{-j\omega_0 \tau(\theta)}$$

$$s_1(t) = s_0(t)e^{-j\omega_0 \tau(\theta)} = s_0(t)e^{-j2\pi \left(\frac{f_0}{c} \right) d \text{sen}(\theta)} = s_0(t)e^{-j\pi \frac{d}{\lambda/2} \text{sen}(\theta)}$$

“Linearly constrained minimum variance” (LCMV)

- PROBLEMA:

$$\text{minimizar } E[|y(n)|^2] = \mathbf{w}^H \mathbf{R}_x \mathbf{w} \quad \text{s.t.} \quad \mathbf{w}^H \mathbf{s}(\theta_0) = g$$

$$\text{siendo } \mathbf{s}(\theta_0) = \left(1 \quad e^{-j\theta_0} \quad \dots \quad e^{-j(M-1)\theta_0} \right)^T$$

- Aplicamos el método de los multiplicadores de Lagrange

$$J(\mathbf{w}) = \mathbf{w}^H \mathbf{R}_x \mathbf{w} + \lambda_R \left(\text{Re}(\mathbf{w}^H \mathbf{s}(\theta_0)) - g_R \right) + \lambda_I \left(\text{Im}(\mathbf{w}^H \mathbf{s}(\theta_0)) - g_I \right)$$

$$J(\mathbf{w}) = \mathbf{w}^H \mathbf{R}_x \mathbf{w} + \text{Re}(\lambda^* (\mathbf{w}^H \mathbf{s}(\theta_0) - g))$$

“Linearly constrained minimum variance” (LCMV)

- Tomando derivadas e igualando a cero

$$\nabla J = 2\mathbf{R}_x \mathbf{w} + \frac{\lambda^*}{2} \mathbf{s}(\theta_0) = 0 \quad \longrightarrow \quad \mathbf{w}_{opt} = -\frac{\lambda^*}{2} \mathbf{R}_x^{-1} \mathbf{s}(\theta_0)$$

- Para obtener el multiplicador de Lagrange

$$\mathbf{w}_{opt}^H \mathbf{s}(\theta_0) = g = -\frac{\lambda}{2} \mathbf{s}^H(\theta_0) \mathbf{R}_x^{-1} \mathbf{s}(\theta_0) \quad \longrightarrow \quad \lambda = -\frac{2g}{\mathbf{s}^H(\theta_0) \mathbf{R}_x^{-1} \mathbf{s}(\theta_0)}$$

- El LCMV o “Minimum variance distortionless response” (MVDR) beamformer es

$$\mathbf{w}_{opt} = \frac{g^* \mathbf{R}_x^{-1} \mathbf{s}(\theta_0)}{\mathbf{s}^H(\theta_0) \mathbf{R}_x^{-1} \mathbf{s}(\theta_0)}$$

MVDR Spectrum

- Tomando $g=1$, la potencia mínima a la salida del conformador es

$$J_{\min} = \frac{1}{\mathbf{s}^H(\theta_0) \mathbf{R}_x^{-1} \mathbf{s}(\theta_0)}$$

que mantiene la respuesta (potencia) en la dirección θ_0 minimizando el resto.

- Considerando la expresión anterior como función de la frecuencia espacial θ , o temporal ω

$$S(\omega) = \frac{1}{\mathbf{s}^H(\omega) \mathbf{R}_x^{-1} \mathbf{s}(\omega)}$$

“MVDR spectrum” o
“Capon spectrum”

Ejemplo LCMV

- Programa: Lcmv.m

-Señal QPSK deseada en $\theta_0 = -20^\circ$

-Interferencia 1 en $\theta_1 = 20^\circ$ con SIR=-10 dB

-Interferencia 2 en $\theta_2 = -60^\circ$ con SIR=-15 dB


-Ruido gaussiano y espacialmente blanco con SNR=0 dB

-Array lineal con M=10 elementos, separación entre antenas $d=\lambda/2$.


Ejemplo LCMV

$N=25$ "snapshots"

Una realización




10 realizaciones ind.



Ejemplo LCMV

$N=250$ "snapshots"

Una realización




I2

D

I1

10 realizaciones ind.




I2

D

I1

Filtro adaptado estocástico I

- Otro problema filtrado óptimo que aparece frecuentemente en comunicaciones es el siguiente:



¿Cuál es el filtro que maximiza la SNR a la salida?

- Potencia de señal a la salida del filtro: $w^H R_s w$
- Potencia de ruido a la salida del filtro: $w^H R_v w$

SNR máxima



maximizar

$$SNR = \frac{w^H R_s w}{w^H R_v w}$$

Filtro adaptado estocástico II

- Si suponemos que el ruido es blanco $\mathbf{R}_v = \sigma_v^2 \mathbf{I}$

$$\text{maximizar} \quad SNR = \frac{1}{\sigma_v^2} \frac{\mathbf{w}^H \mathbf{R}_s \mathbf{w}}{\mathbf{w}^H \mathbf{w}}$$

- El problema es equivalente a

$$\text{maximizar} \quad \frac{\mathbf{w}^H \mathbf{R}_s \mathbf{w}}{\mathbf{w}^H \mathbf{w}} \quad \text{s.t.} \quad \mathbf{w}^H \mathbf{w} = 1$$

- La solución es el autovector correspondiente al máximo autovalor de : \mathbf{R}_s

$$\mathbf{w}_{opt} = \mathbf{q}_{\max} \quad \text{siendo} \quad \mathbf{R}_s \mathbf{q}_{\max} = \lambda_{\max} \mathbf{q}_{\max} \quad \text{y la} \quad SNR_{\max} = \frac{\lambda_{\max}}{\sigma_v^2}$$

- Puede verse como un filtro adaptado estocástico, también se denomina en la literatura "eigenfilter".

Conclusiones

- El filtrado lineal óptimo (filtro de Wiener) aparece en multitud de problemas de comunicaciones.
- Su obtención requiere conocer (o estimar) los estadísticos de 2º orden.
- El filtro de Wiener extrae de la entrada la parte correlada con la señal deseada (si $\mathbf{p}=0$, $\mathbf{w}=0$).
- La señal de error resultante está incorrelada con la entrada (y con la salida del filtro): Principio de ortogonalidad.
- Minimización del MSE sujeto a una restricción lineal (LCMV).
- Maximización de la potencia de salida sujeto a una restricción cuadrática ("eigenfilters").