

# Análise e Processamento de Sinal e Imagem

## III - Sinais Aleatórios e Filtragem Óptima

António M. Gonçalves Pinheiro

Departamento de Física  
Universidade da Beira Interior  
Covilhã - Portugal

pinheiro@ubi.pt

## Sinais Aleatórios e Filtragem Óptima


---

1. Noção de Sinal Aleatório
2. Sinais Estocásticos, Processos Ergódicos e Sinais Estacionários
3. Funções de Correlação
4. Função espectral de Potência
5. Filtros de Wiener
6. Filtro de Kalman


## Sinais Aleatórios

Processos Estocásticos - Sinais que variam aleatoriamente no tempo.

**Sinais Aleatórios** são regidos por processos estocásticos.



Ruído Aleatório Gaussiano




Pressão Arterial




## Sinais Aleatórios

### Sinais Contínuos e Discretos



Sinal contínuo -  $x(t)$



Sinal discreto -  $x[n]$


## Sinais Aleatórios

### Média temporal e média conjunta

	Sinal Contínuo	Sinal Discreto
Sinal aleatório com potência média finita	$x(t)$	$x[n]$
<i>Média Temporal</i> Componente contínua do sinal	$\langle x(t) \rangle$	$\langle x[n] \rangle$
<i>Média Quadrática Temporal</i> Potência média do sinal	$\langle x^2(t) \rangle$	$\langle x^2[n] \rangle$
<i>Média Conjunta</i>	$E [x(t)]$	$E [x[n]]$
<i>Média Quadrática Conjunta</i>	$E [x^2(t)]$	$E [x^2[n]]$

## Sinais Aleatórios

## Calculo de médias conjuntas



## Sinais Aleatórios

### Processos estacionário

*Definição:* Num processo estacionário as médias conjuntas são independentes do tempo de observação.

$$E \{x^m[n]\} = E \{x^m[n + k]\}$$

### Processos ergódicos

*Definição:* Um processo estocástico é um processo ergódico se as médias conjuntas são iguais às médias temporais. Ou seja:

$$\langle x^m[n] \rangle = E \{x^m[n]\}$$







*Nota 1:* Os processos ergódicos são estacionários

*Nota 2:*

$$E \{g(x)\} = \int_{-\infty}^{+\infty} g(x)p(x)dx \qquad E \{g[n]\} = \sum_{n=-\infty}^{+\infty} g[n]p[n]$$







## Sinais Aleatórios

### Exemplos de Sinais Aleatórios









## Sinais Aleatórios

### Exemplos de Sinais Aleatórios



## Sinais Aleatórios

### Exemplos de Sinais Aleatórios



## Sinais Aleatórios

### Propriedades do processo ergódicos

- A média  $\bar{x} = \langle x[n] \rangle = E \{x[n]\}$  é a componente contínua (DC) do sinal  $x[n]$ .
- O quadrado da média,  $\bar{x}^2$ , é a potência DC.
- A média quadrada,  $\bar{x}^2 = \langle x^2[n] \rangle = E \{x^2[n]\}$ , é a potência média do sinal.
- A variância  $\sigma_x^2 = \bar{x}^2 - \bar{x}^2$  é a potência relativa à parte do sinal que varia no tempo, ou seja, sem componente DC.
- O desvio padrão  $\sigma_x$  é o valor eficaz do sinal.

## Sinais Aleatórios

### Funções de Correlação

#### Sinais Discretos

#### Sinais Contínuos

#### Correlação cruzada

$$R_{xy}[k] = E \{x[n]y^*[n - k]\}$$

$$R_{xy}(\tau) = E \{x(t)y^*(t - \tau)\}$$

#### Auto-correlação

$$R_x[k] = E \{x[n]x^*[n - k]\}$$

$$R_x(\tau) = E \{x(t)x^*(t - \tau)\}$$

## Sinais Aleatórios

### Propriedades da Auto-correlação:

- $R_x[-k] = R_x[k]$  - Função Par
- $R_x[0] = \bar{x}^2 = \sigma_x^2 + \bar{x}^2 \geq R_x[k]$
- De 1 e 2 pode-se concluir que  $R_x[k]$  é uma função par com um máximo em  $k = 0$
- Em processos não periódicos  $\lim_{k \rightarrow +\infty} R_x[|k|] = \bar{x}^2$
- No caso de processos periódicos, a autocorrelação é também periódica, com o mesmo período que o processo.

*Nota:* Provar que  $E\{x[k - k_1]x[k - k_2]\} = R_x[k_1 - k_2]$  se  $x[k]$  for um processo ergódico e real.

## Sinais Aleatórios

---

### Processo Estacionário em Sentido Restrito - WSS

WSS - "Wide Sense Stationarity"

*Condições de Estacionaridade*

1. A média do processo é constante:  $\langle x[n] \rangle = \bar{x}$ .
2. A autocorrelação do processo  $R_x[k]$  só depende do valor de  $k$ .
3. A variância do processo é finita:  $\sigma_x^2 = \langle x^2[n] \rangle - \bar{x}^2 < \infty$

## Sinais Aleatórios

Densidade Espectral de Potência -  $P_x$

### Teorema de Wiener-Kinchine

Sinal contínuo -  $x(t)$

$$R_x(\tau) \xleftrightarrow{\text{TF}} P_x(j\omega) = \int_{-\infty}^{+\infty} E[x(t)x^*(t-\tau)] e^{-j\omega\tau} d\tau$$

Sinal discreto -  $x[n]$

$$R_x[k] \xleftrightarrow{\text{TF}} P_x(e^{j\Omega}) = \sum_{k=-\infty}^{+\infty} E[x[n]x^*[n-k]] e^{-j\Omega k}$$

## Sinais Aleatórios

Densidade Espectral de Potência -  $P_x$

**Relação entre a entrada e a saída num SLIT**

Sistema contínuo -  $h(t)$

$$R_y(\tau) \xleftrightarrow{\text{TF}} P_y(j\omega) = |H(j\omega)|^2 P_x(j\omega)$$

Sistema discreto -  $h[n]$

$$R_y[k] \xleftrightarrow{\text{TF}} P_y(e^{j\Omega}) = |H(e^{j\Omega})|^2 P_x(e^{j\Omega})$$

## Sinais Aleatórios

### Propriedades da Densidade Espectral de Potência de um Processo Estacionário

#### Sinais Discretos

1. *Simetria:*  $P_x(e^{j\Omega}) = P_x^*(e^{j\Omega})$   
Se  $x[n]$  é real, então  $P_x(e^{j\Omega}) = P_x(e^{-j\Omega})$   
(função par)

2. *Positividade:*  $P_x(e^{j\Omega}) \geq 0$

3. *Potência total:*

$$\bar{x}^2 = R_x[0] = \frac{1}{2\pi} \int_{-\pi}^{\pi} P_x(e^{j\Omega}) d\Omega$$

#### Sinais Contínuos

1. *Simetria:*  $P_x(j\omega) = P_x^*(j\omega)$   
Se  $x(t)$  é real, então  $P_x(j\omega) = P_x(-j\omega)$   
(função par)

2. *Positividade:*  $P_x(j\omega) \geq 0$

3. *Potência total:*

$$\bar{x}^2 = R_x(0) = \frac{1}{2\pi} \int_{-\infty}^{\infty} P_x(j\omega) d\omega$$

## Sinais Aleatórios

### Exemplo 1

$$x(t) = A \cos(\omega_0 t + \theta)$$

com  $A$  e  $\omega_0$  constantes e  $\theta$  varia aleatoriamente de forma uniformemente distribuída (entre  $-\pi < \theta \leq \pi$ ).

Resolução:

$$R_x(\tau) = E \{x(t)x^*(t - \tau)\} = \frac{A^2}{2} E \{\cos(\omega_0 \tau)\} + \frac{A^2}{2} E \{\cos(2\omega_0 t - \omega_0 \tau + 2\theta)\}$$

$$E \{\cos(2\omega_0 t - \omega_0 \tau + 2\theta)\} = \int_{-\infty}^{+\infty} \cos(2\omega_0 t - \omega_0 \tau + 2\theta) p(\theta) d\theta = \frac{1}{2\pi} \int_{-\pi}^{+\pi} \cos(2\omega_0 t - \omega_0 \tau + 2\theta) d\theta = 0$$


Solução:

$$R_x(\tau) = \frac{A^2}{2} \cos(\omega_0 \tau) \xleftrightarrow{\text{TF}} P_x(j\omega) = \frac{A^2 \pi}{2} (\delta(\omega - \omega_0) + \delta(\omega + \omega_0))$$

## Sinais Aleatórios

## Exemplo 2

Onda binária aleatória:



Em  $(n - 1)T < t - T_d < nT$ ,  $x(t)$  assume valor  $+A$  ou  $-A$  de forma equiprovável. O tempo de atraso  $T_d$  é uma variável aleatória uniformemente distribuída no intervalo  $[0, T]$ .

Resolução:

$$R_x(\tau) = E \{x(t)x^*(t - \tau)\}$$

Se  $|\tau| > T$  estamos perante duas amostras diferentes e independentes da onda binária. Como os símbolos são equiprováveis  $E \{x(t)x^*(t - \tau)\} = E \{x(t)\} E \{x^*(t - \tau)\} = 0$

$x(t)$  e  $x(t - \tau)$  só estão no mesmo intervalo se:  $t + (T_d - T) < t - |\tau| \Rightarrow T_d < T - |\tau|$ .

Nesse caso



$$E \{x(t)x^*(t - \tau)\} = A^2 \int_0^{T-|\tau|} \frac{1}{T} dT_d = A^2 \left(1 - \frac{|\tau|}{T}\right)$$

## Sinais Aleatórios

## Exemplo 2 (continuação)

Solução:

$$R_x(\tau) = A^2 \Lambda(\tau/T) = A^2 \left(1 - \frac{|\tau|}{T}\right) [u(t+T) - u(t-T)] \xleftrightarrow{\text{TF}} P_x(j\omega) = A^2 T \text{sinc}^2\left(\frac{\omega T}{2\pi}\right)$$



## Sinais Aleatórios

### Ruído Térmico

Ruído térmico que surge devido ao movimento de electrões e portanto surge inevitavelmente associado à corrente eléctrica em materiais condutores.

O ruído térmico é uma variável aleatória  $x(t)$  com distribuição gaussiana, em que:

- $\bar{x} = 0$

- $\bar{x^2} = \sigma_x^2 = \frac{2(\pi KT)^2}{3h} RV^2$ , em que
  - $T$  - Temperatura
  - $K$  - constante de Boltzman
  - $h$  - constante de Plank

- $P_x(j\omega) = \frac{Rh|\omega|}{\pi (e^{h\omega/(2\pi KJ)} - 1)} [V^2/Hz]$

## Sinais Aleatórios

### Ruído Branco

Caracterizado por:

- variável aleatória gaussiana.
- $P(j\omega) = \eta/2$  - densidade espectral de potência constante ao longo de grande faixas de frequências.
- $R(\tau) = \mathcal{TF}^{-1} \{P(j\omega)\} = (\eta/2)\delta(\tau)$

*Propriedade:*

$R(\tau \neq 0) = 0$ , logo 2 amostras diferentes de um sinal de ruído branco gaussiano, são sempre:

- não correlacionadas  $\implies$  logo são estatisticamente independentes



## Sinais Aleatórios

## Filtragem de Ruído Branco

Considerando:

- $h(t)$  - filtro passa baixo ideal com largura de banda  $B$
- $x(t)$  - ruído branco

$$P_y(j\omega) = \frac{\eta}{2} \Pi\left(\frac{\omega}{2B}\right) \xleftrightarrow{\text{TF}} R_y(\tau) = \eta B \text{sinc}(2B\tau)$$



## Sinais Aleatórios

### Propriedade

Se a entrada de um sistema linear e invariante no tempo for um sinal aleatório gaussiano, então a saída será um sinal aleatório gaussiano.

- podem mudar as médias estatísticas, mas não muda o modelo de probabilidade.
- ruído branco filtrado origina sinal aleatório gaussiano, que não é ruído branco.


### Relação Sinal Ruído - SNR

Considerando um sinal  $d[n]$  corrompido com ruído branco gaussiano  $v[n]$ , em que resulta  $x[n] = d[n] + v[n]$ , define-se:

$$\text{SNR} = \frac{R_d[0]}{\sigma_v^2}$$

SNR - medida da potência do ruído relativamente à potência do sinal.

## Estimação Linear - Filtragem Óptima



- $d[n]$  - Sinal
- $v[n]$  - Ruído
- $x[n]$  - Sinal corrompido com ruído
- $\hat{d}[n]$  - Sinal Estimado

**Objectivo** - Estimar um sinal aleatório que só está disponível corrompido com ruído.

Duas soluções:

- Filtro de Wiener - *Sinais Estacionários (WSS - Sentido Restrito)*
- Filtro de Kalman - *Sinais Não Estacionários*

## Estimação Linear - Filtragem Óptima

Problemas a considerar:

- **Filtragem** - Estimar  $\hat{d}[n]$  quando o sinal está corrompido com ruído,  $x[n] = d[n] + v[n]$  com um *filtro estimador* causal, ou seja, considerando o valor presente e passados de  $x[n]$ .
- **Suavização** - O mesmo problema, mas considerando todos os dados possíveis, sendo permitido que o *filtro estimador* não causal.
- **Predição** - Sinal é estimado em  $n + k$  (futuro), usando dados observados até  $n$ .
- **Desconvolução** - Quando  $x[n] = d[n] * g[n] + v[n]$ , em que  $g[n]$  é a resposta impulsiva de um SLIT.

## Estimação Linear - Filtragem Óptima

### Filtros **FIR** de Wiener

Filtro estimador -  $w[n] \xleftrightarrow{Z} W(z)$

O filtro **FIR de Wiener** produz uma *estimativa do erro quadrático médio mínimo* do processo  $d[n]$  filtrando o processo estatisticamente relacionado  $x[n]$ .

Assume-se que os processos  $x[n]$  e  $d[n]$  são estacionários em sentido restrito com:

- autocorrelação de  $x[n]$  -  $R_x[k]$
- autocorrelação de  $d[n]$  -  $R_d[k]$
- correlação cruzada:  $R_{dx}[k]$

## Estimação Linear - Filtragem Óptima

### Filtros **FIR** de Wiener

$N$  - comprimento do filtro **FIR de Wiener**

$$W(z) = \sum_{k=0}^{N-1} w[k]z^{-k}$$

A estimativa do filtro à saída é dada pela convolução:

$$\hat{d}[n] = \sum_{l=0}^{N-1} w[l]x[n-l]$$

O filtro **FIR de Wiener** leva a coeficientes  $w[n]$  que minimiza o erro quadrático médio, ou seja:

$$\xi = E \left\{ |e[n]|^2 \right\} = E \left\{ \left| d[n] - \hat{d}[n] \right|^2 \right\} \Rightarrow \frac{\partial \xi}{\partial w[m]} = 0$$

## Estimação Linear - Filtragem Óptima

### Filtros **FIR** de Wiener

Manipulando matematicamente, obtemos (*Princípio da ortogonalidade*):

$$\frac{\partial \xi}{\partial w[m]} = 0 \Rightarrow E \{e[n]x^*[n-m]\} = 0, \quad m = 0, 1, \dots, N-1$$

Considerando

$$e[n] = d[n] - \hat{d}[n] = d[n] - \sum_{l=0}^{N-1} w[l]x[n-l]$$

Resulta

$$E \{d[n]x^*[n-m]\} - \sum_{l=0}^{N-1} w[l]E \{x[n-l]x^*[n-m]\} = 0$$

Ou seja:

$$\sum_{l=0}^{N-1} w[l]R_x[m-l] = R_{dx}[m], \quad m = 0, 1, \dots, N-1$$

## Estimação Linear - Filtragem Óptima

### Filtros FIR de Wiener

Considerando que  $R_x[k] = R_x^*[-k]$  resulta um sistema de equações na forma matricial (*Equações de Winer-Hopf*):

$$\mathbf{R}_x \mathbf{w} = \mathbf{R}_{dx} \Leftrightarrow \mathbf{w} = \mathbf{R}_x^{-1} \mathbf{R}_{dx}$$

$$\mathbf{R}_x = \begin{bmatrix} R_x[0] & R_x^*[1] & \dots & R_x^*[N-1] \\ R_x[1] & R_x[0] & \dots & R_x^*[N-2] \\ R_x[2] & R_x[1] & \dots & R_x^*[N-3] \\ \cdot & \cdot & & \cdot \\ \cdot & \cdot & & \cdot \\ \cdot & \cdot & & \cdot \\ R_x[N-1] & R_x[N-2] & \dots & R_x[0] \end{bmatrix} \quad \mathbf{w} = \begin{bmatrix} w[0] \\ w[1] \\ w[2] \\ \cdot \\ \cdot \\ \cdot \\ w[N-1] \end{bmatrix} \quad \mathbf{R}_{dx} = \begin{bmatrix} R_{dx}[0] \\ R_{dx}[1] \\ R_{dx}[2] \\ \cdot \\ \cdot \\ \cdot \\ R_{dx}[N-1] \end{bmatrix}$$

$\mathbf{R}_x$  - Matriz de autocorrelação, Hermitiana e de "Toeplitz"

$\mathbf{w}$  - vector dos coeficientes do filtro

$\mathbf{R}_{dx}$  - vector de correlação cruzada entre o sinal desejado  $d[n]$  e o sinal observado  $x[n]$ .

## Estimação Linear - Filtragem Óptima

### Filtros **FIR** de Wiener

#### **Equações de Wiener-Hopf** para o filtro **FIR de Wiener**

$$\textit{Equações de Wiener-Hopf} \quad \sum_{l=0}^{N-1} w[l] R_x[m-l] = R_{dx}[m], \quad m = 0, 1, \dots, N-1$$

$$\textit{Correlações} \quad R_x = E \{x[n]x^*[n-m]\}$$

$$R_{dx} = E \{d[n]x^*[n-m]\}$$


$$\textit{Mínimo Erro} \quad \xi_{min} = R_d(0) - \sum_{l=0}^{N-1} w[l] R_{dx}^*[l]$$

$$\mathbf{w} = \mathbf{R}_x^{-1} \mathbf{R}_{dx} \quad \Rightarrow \quad \xi_{min} = R_d(0) - \mathbf{R}_{dx}^H \mathbf{R}_x^{-1} \mathbf{R}_{dx}$$

## Estimação Linear - Filtragem Óptima

Exemplo de Estimação com Filtro **FIR** de Wiener


Sinal corrompido  $x[n]$



## Estimação Linear - Filtragem Óptima

Exemplo de Estimação com Filtro FIR de Wiener


Sinal corrompido  $x[n]$  e sinal original  $d[n]$ .



## Estimação Linear - Filtragem Óptima

Exemplo de Estimação com Filtro FIR de Wiener


Sinal corrompido  $x[n]$ , sinal original  $d[n]$  e sinal estimado  $\hat{d}[n]$



## Estimação Linear - Filtragem Óptima

Exemplo de Estimação com Filtro FIR de Wiener

Sinal original  $d[n]$  e sinal estimado  $\hat{d}[n]$



## Estimação Linear - Filtragem Óptima


### Filtros FIR de Wiener - Filtragem

Sinal  $d[n]$  corrompido com ruído  $v[n]$ , resultando em:

$$x[n] = d[n] + v[n]$$

Exemplos de aplicação:

- recuperação de sinais adquiridos em ambientes ruidosos
- enriquecimento da qualidade de imagem
- restauração de gravações antigas



Consideramos o ruído e o sinal não correlacionados. Logo  $R_{dv}[k] = E \{d[n]v^*[n - k]\} = 0$ . Então:

$$R_{dx}[k] = E \{d[n]x^*[n - k]\} = E \{d[n]d^*[n - k]\} + E \{d[n]v^*[n - k]\} = R_d[k]$$

$$R_x[k] = E \{x[n + k]x^*[n]\} = E \{[d[n + k] + v[n + k]] [d[n] + v[n]]^*\} = R_d[k] + R_v[k]$$

**Equação de Wiener-Hopf**  
(ruído e sinal não correlacionados)

$$[\mathbf{R}_d + \mathbf{R}_v] \mathbf{w} = \mathbf{R}_d$$

## Estimação Linear - Filtragem Óptima

### Filtros FIR de Wiener - Exemplo de Filtragem

Consideremos um processo estacionário  $d[n]$  com autocorrelação  $R_d[k] = \alpha^{|k|}$ .  $|\alpha| < 1$

corrompido com ruído branco não correlacionado com variância  $\sigma_v^2$ , tal que  $x[n] = d[n] + v[n]$ .

Pretende-se desenhar um filtro FIR de Wiener de primeira ordem (comprimento 2) para reduzir o efeito do ruído e obter a melhor estimativa de  $d[n]$ .

Logo, o filtro será dado por:  $W(z) = w[0] + w[1]z^{-1}$   $N = 2$

sendo a equação de Wiener-Hopf dada por: 
$$\begin{bmatrix} R_x[0] & R_x[1] \\ R_x[1] & R_x[0] \end{bmatrix} \begin{bmatrix} w[0] \\ w[1] \end{bmatrix} = \begin{bmatrix} R_{dx}[0] \\ R_{dx}[1] \end{bmatrix}$$

resulta

$$W(z) = \frac{1}{(1 + \sigma_v^2)^2 - \alpha^2} [(1 + \sigma_v^2 - \alpha^2 + \alpha\sigma_v^2 z^{-1})]$$

## Estimação Linear - Filtragem Óptima

### Filtros FIR de Wiener - Exemplo de Filtragem

Considerando  $\alpha = 0.8$  e  $\sigma_v^2 = 1$  obtemos:

SNR sem o filtro:

$$\text{SNR} = \frac{R_d[0]}{\sigma_v^2} = \frac{\alpha^0}{\sigma_v^2} = 1$$


SNR com o filtro:

$$\text{SNR} = \frac{E \left\{ |w[n] * d[n]|^2 \right\}}{E \left\{ |w[n] * v[n]|^2 \right\}}$$


$$\text{SNR} = \frac{\mathbf{w}^T \mathbf{R}_d \mathbf{w}}{\mathbf{w}^T \mathbf{R}_v \mathbf{w}} = \frac{0.37748}{0.2206}$$

Logo a SNR será dada por:

$$\text{SNR}_{dB} = 10 \log_{10} \frac{0.37748}{0.2206} = 2.302 dB$$



Amplitude do espectro de potência do processo  $d[k]$ .



Resposta em Amplitude do filtro de Wiener

## Estimação Linear - Filtragem Óptima

### Filtros de Wiener - Predicção


Neste caso o objectivo é estimar o sinal em  $n + 1$ ,  $x[n + 1]$ :

$$\hat{x}[n + 1] = \sum_{k=0}^{N-1} w[k]x[n - k]$$

Se considerarmos  $d[n] = x[n + 1]$  temos uma situação idêntica à anterior.

Sendo

$$R_{dx}[k] = E \{d[n]x^*[n - k]\} = E \{x[n + 1]x^*[n - k]\} = R_x[k + 1]$$



## Estimação Linear - Filtragem Óptima

### Filtros de Wiener - Predicção

As equações de Wiener-Hopf resultantes são dadas por:

$$\begin{bmatrix} R_x[0] & R_x^*[1] & \dots & R_x^*[N-1] \\ R_x[1] & R_x[0] & \dots & R_x^*[N-2] \\ R_x[2] & R_x[1] & \dots & R_x^*[N-3] \\ \cdot & \cdot & & \cdot \\ \cdot & \cdot & & \cdot \\ \cdot & \cdot & & \cdot \\ R_x[N-1] & R_x[N-2] & \dots & R_x[0] \end{bmatrix} \begin{bmatrix} w[0] \\ w[1] \\ w[2] \\ \cdot \\ \cdot \\ \cdot \\ w[N-1] \end{bmatrix} = \begin{bmatrix} R_{dx}[1] \\ R_{dx}[2] \\ R_{dx}[3] \\ \cdot \\ \cdot \\ \cdot \\ R_{dx}[N] \end{bmatrix}$$

Sendo o erro quadrático médio dado por:

$$\xi_{min} = R_x(0) - \sum_{k=0}^{N-1} w[k] R_x^*[k+1]$$

## Estimação Linear - Filtragem Óptima

### Filtros de Wiener - Exemplo de Predicção

Consideremos um processo estacionário  $x[n]$  com autocorrelação  $R_x[k] = \alpha^{|k|}$ .

O preditor de primeira ordem (comprimento 2) é da forma:

$$\hat{x}[n+1] = w[0]x[n] + w[1]x[n-1]$$

Resultando nas **equações de Wiener-Hopf**:

$$\begin{bmatrix} 1 & \alpha \\ \alpha & 1 \end{bmatrix} \begin{bmatrix} w[0] \\ w[1] \end{bmatrix} = \begin{bmatrix} \alpha \\ \alpha^2 \end{bmatrix}$$

O preditor de primeira ordem é dado por:  $\hat{x}[n+1] = \alpha x[n]$


## Estimação Linear - Filtragem Óptima

### Filtros de Wiener - Predicção no ruído

Neste caso o objectivo é estimar o sinal em  $n + 1$ ,  $x[n + 1]$ , quando ele se encontra corrompido com ruído:

Sendo assim

$$\hat{x}[n + 1] = \sum_{k=0}^{N-1} w[k]y[n - k]$$



Sendo a **equação de Wiener-Hopf** dada por:

$$\mathbf{R}_y \mathbf{w} = \mathbf{R}_{dy}$$

com  $\mathbf{R}_y = \mathbf{R}_x + \mathbf{R}_v$  caso o sinal e o ruído sejam não correlacionados.

## Estimação Linear - Filtragem Óptima

Filtros de Wiener - **Predicção de amostra**  $n + m$

**Equações de Wiener-Hopf:**

$$\begin{bmatrix} R_x[0] & R_x^*[1] & \dots & R_x^*[N-1] \\ R_x[1] & R_x[0] & \dots & R_x^*[N-2] \\ R_x[2] & R_x[1] & \dots & R_x^*[N-3] \\ \cdot & \cdot & & \cdot \\ \cdot & \cdot & & \cdot \\ \cdot & \cdot & & \cdot \\ R_x[N-1] & R_x[N-2] & \dots & R_x[0] \end{bmatrix} \begin{bmatrix} w[0] \\ w[1] \\ w[2] \\ \cdot \\ \cdot \\ \cdot \\ w[N-1] \end{bmatrix} = \begin{bmatrix} R_{dx}[m] \\ R_{dx}[m+1] \\ R_{dx}[m+2] \\ \cdot \\ \cdot \\ \cdot \\ R_{dx}[m+N-1] \end{bmatrix}$$

## Estimação Linear - Filtragem Óptima

### Filtros de Wiener IIR

Consideramos o filtro IIR de Wiener com função impulsiva  $h[n]$  com função de transferência dada por:

$$H(z) = \sum_{k=-\infty}^{+\infty} h[k]z^{-k}$$

$H(z)$  é tal que minimiza o erro quadrático médio:

$$\xi = E \left\{ |e[n]|^2 \right\}, \quad \text{com } e[n] = d[n] - \hat{d}[n] = d[n] - \sum_{l=-\infty}^{+\infty} h[l]x[n-l]$$

O mínimo do erro quadrático médio implica:

$$\frac{\partial \xi}{\partial h[m]} = 0 \Rightarrow E \{ e[n]x^*[n-m] \} = 0; \quad -\infty < m < +\infty$$

## Estimação Linear - Filtragem Óptima

### Filtros de Wiener IIR

Combinando as duas últimas expressões:

$$\sum_{l=-\infty}^{+\infty} h[l]R_x[m-l] = R_{dx}[k]; \quad -\infty < m < +\infty$$

Que é equivalente a:

$$h[m] * R_x[m] = R_{dx}[m]$$

Que resulta no domínio da frequência no filtro não causal

$$H(e^{j\Omega}) = \frac{P_{dx}(e^{j\Omega})}{P_x(e^{j\Omega})}$$

Neste caso, o erro quadrático médio mínimo é dado por:

$$\xi_{min} = R_d(0) - \sum_{l=-\infty}^{+\infty} h[l]R_{dx}^*(l) = R_d(0) - \frac{1}{2\pi} \int_{-\pi}^{\pi} H(e^{j\Omega}) P_{dx}(e^{j\Omega}) d\Omega$$

## Estimação Linear - Filtragem Óptima

### Filtros de Wiener IIR Causal

Aproximação semelhante, só que consideramos a resposta impulsiva nula para  $n < 0$

$$\hat{d}[n] = x[n] * h[n] = \sum_{k=0}^{+\infty} h[k]x[n-k] \Rightarrow \sum_{l=0}^{+\infty} h[l]R_x[k-l] = R_{dx}[k]$$

### Função de Transferência

$$H(z) = \frac{1}{\sigma_0^2 Q(z)} \frac{P_{dx}(z)}{Q^*(1/z^*)}$$

Em que  $Q(z)$  resulta da factorização espectral de

$$P_x(z) = \sigma_0^2 Q(z)Q^*(1/z^*)$$

### Erro Mínimo

$$\xi_{min} = R_d(0) - \sum_{l=0}^{+\infty} h[l]R_{dx}^*(l) = \frac{1}{2\pi} \int_{-\pi}^{\pi} (P_d(e^{j\Omega}) - H(e^{j\Omega})P_{dx}(e^{j\Omega})) d\Omega$$

## Estimação Linear - Filtragem Óptima

### Filtro de Kalman Discreto

Filtro de Wiener requer sinais  $d[n]$  e  $x[n]$   
WSS

Os **filtros de Kalman** são aplicados a sinais não estacionários.

Equação de Estado

$$\mathbf{d}[n] = \mathbf{A}[n-1] \mathbf{d}[n-1] + \mathbf{w}[n]$$

Equação de Observação

$$\mathbf{d}[n] = \mathbf{A}[n-1] \mathbf{d}[n-1] + \mathbf{w}[n]$$

Inicialização

$$\hat{\mathbf{d}}[0|0] = E \{ \mathbf{d}[0] \}$$

$$\mathbf{P}[0|0] = E \{ \mathbf{d}[0] \mathbf{d}^H[0] \}$$

Cálculo

Para  $n = 1, 2, \dots$ , calcular

$$\hat{\mathbf{d}}[n|n-1] = \mathbf{A}[n-1] \hat{\mathbf{d}}[n-1|n-1]$$

$$\mathbf{P}[n|n-1] = \mathbf{A}[n-1] \mathbf{P}[n-1|n-1] \mathbf{A}^H[n-1] + \mathbf{Q}_w[n]$$

$$\mathbf{K}[n] = \mathbf{P}[n|n-1] \mathbf{C}^H[n]$$

$$[\mathbf{C}[n] \mathbf{P}[n|n-1] \mathbf{C}^H[n] + \mathbf{Q}_v[n]]^{-1}$$

$$\hat{\mathbf{d}}[n|n] = \hat{\mathbf{d}}[n|n-1] + \mathbf{K}[n] [\mathbf{x}[n] - \mathbf{C}[n] \hat{\mathbf{d}}[n|n-1]]$$

$$\mathbf{P}[n|n] = [\mathbf{I} - \mathbf{K}[n] \mathbf{C}[n]] \mathbf{P}[n|n-1]$$

## Estimação Linear - Filtragem Óptima

### Filtro de Kalman Discreto - Exemplo

Estimação de um valor constante corrompido por ruído branco não correlacionado de média nula.

Nesse caso a equação de estado é dada por:  $d[n] = d[n - 1]$

Sendo observado:  $x[n] = d[n] + v[n]$

Logo:  $\mathbf{A}[n] = 1$ ,  $\mathbf{C}[n] = 1$ ,  $\mathbf{Q}_w[n] = 0$  e  $\mathbf{Q}_v[n] = \sigma_v^2$

Como  $x[n]$  é um escalar, a covariância do erro também é escalar,  $P[n|n] = E \{e^2[n|n]\}$ , com  $e[n|n] = d[n] - \hat{d}[n|n]$

Aplicando as equações:

$$P[n - 1] = P[n|n - 1] = P[n - 1|n - 1], k[n] = P[n - 1] [P[n - 1] + \sigma_v^2]^{-1}$$

$$P[n] = [1 - K[n]] P[n - 1] = \frac{P[n - 1]\sigma_v^2}{P[n - 1] + \sigma_v^2} \Leftrightarrow P[n] = \frac{P[0]\sigma_v^2}{n P[0] + \sigma_v^2}$$

$$k[n] = \frac{P[n - 1]}{P[n - 1] + \sigma_v^2} = \frac{P[0]}{n P[0] + \sigma_v^2}$$

## Estimação Linear - Filtragem Óptima

### Filtro de Kalman Discreto - Exemplo

Obtemos então para o filtro de Kalman:

$$\hat{d}[n] = \hat{d}[n-1] + \frac{P[0]}{n P[0] + \sigma_v^2} [x[n] - \hat{d}[n-1]]$$

Nota:

Supor que  $\hat{d}[0] = 0$  e que  $P[0] \rightarrow \infty$ , ou seja, não há qualquer informação à priori sobre  $d$ . Então:

$$k[n] = \frac{1}{n} \Rightarrow \hat{d}[n] = \frac{n-1}{n} \hat{d}[n-1] + \frac{1}{n} x[n] = \frac{1}{n} \sum_{k=1}^n x[k]$$

Ou seja, a média.