

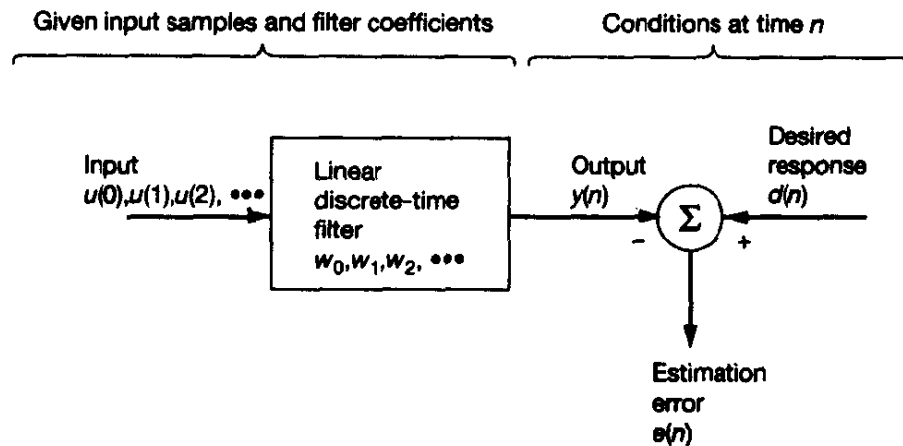
# Filtros de Wiener

## Introdução à Filtragem Linear Ótima

- ❖ Esta aula trata de uma classe de filtros lineares ótimos discretos no tempo conhecidos como Filtros de Wiener.
  - A teoria para um filtro de Wiener é formulada para o caso geral de séries temporais de valor complexo com o filtro especificado em termos de sua resposta impulsiva. A razão para o uso destas séries é que em muitas situações práticas (ex. comunicação, radar, sonar) o sinal de banda base de interesse aparece na forma complexa.
    - O termo banda base é usado para designar a banda de frequências do sinal original gerado pela fonte de informação.
    - Este estudo é iniciado pelo problema da filtragem linear ótima...

# Introdução à Filtragem Linear Ótima

❖ Seja o filtro linear discreto no tempo:



Block diagram representation of the statistical filtering problem.

- A entrada consiste de uma série temporal  $u(0), u(1), u(2), \dots$ , e o filtro é caracterizado pela resposta impulsiva  $w_0, w_1, w_2, \dots$
- Em um tempo discreto  $n$ , o filtro produz uma saída denotada por  $y(n)$ . Esta saída é usada para prover uma estimativa de uma resposta desejada que pode ser denotada por  $d(n)$ .
- Com a entrada do filtro e a resposta desejada representando realizações simples de processos estocásticos, a estimação é acompanhada por um erro com características estatísticas próprias. Em particular, o erro estimado, denotado por  $e(n)$ , é definido como sendo a diferença entre a resposta desejada  $d(n)$  e a saída do filtro  $y(n)$ . O requisito básico é fazer o erro estimado  $e(n)$  o menor possível num sentido estatístico.

# Introdução à Filtragem Linear Ótima

- ❖ Até aqui, duas restrições foram impostas ao filtro:
  - O filtro é linear, o que facilita sua análise matemática
  - O filtro opera num tempo discreto, o que torna possível sua implementação usando hardware/software digital.
- ❖ Entretanto, os detalhes finais da especificação do filtro dependem de duas outras escolhas a serem feitas:
  - Se a resposta impulsiva é de duração finita ou infinita
    - A escolha da duração finita (finite-duration impulse response, FIR) ou infinita (infinite-duration impulse response, IIR) é ditada por considerações práticas.
  - Qual o tipo de critério estatístico será usada para a otimização.
    - A escolha do critério estatístico para otimização do filtro é influenciada pela tratabilidade (acessabilidade) matemática.

## Em resumo: Problema que se encontra em engenharia:

❖ Estimação de um sinal desejado [  $s(n)$  ] a partir de um outro [  $x(n)$  ] em que  $x(n)$  consiste do sinal desejado mais um sinal de ruído ou interferência  $v(n)$ .

$$x(n) = s(n) + v(n)$$

➤ objetivo:

projetar um filtro que minimiza a interferência aditiva e ao mesmo tempo preserva as características do sinal desejado.

❖ Filtros Clássicos:

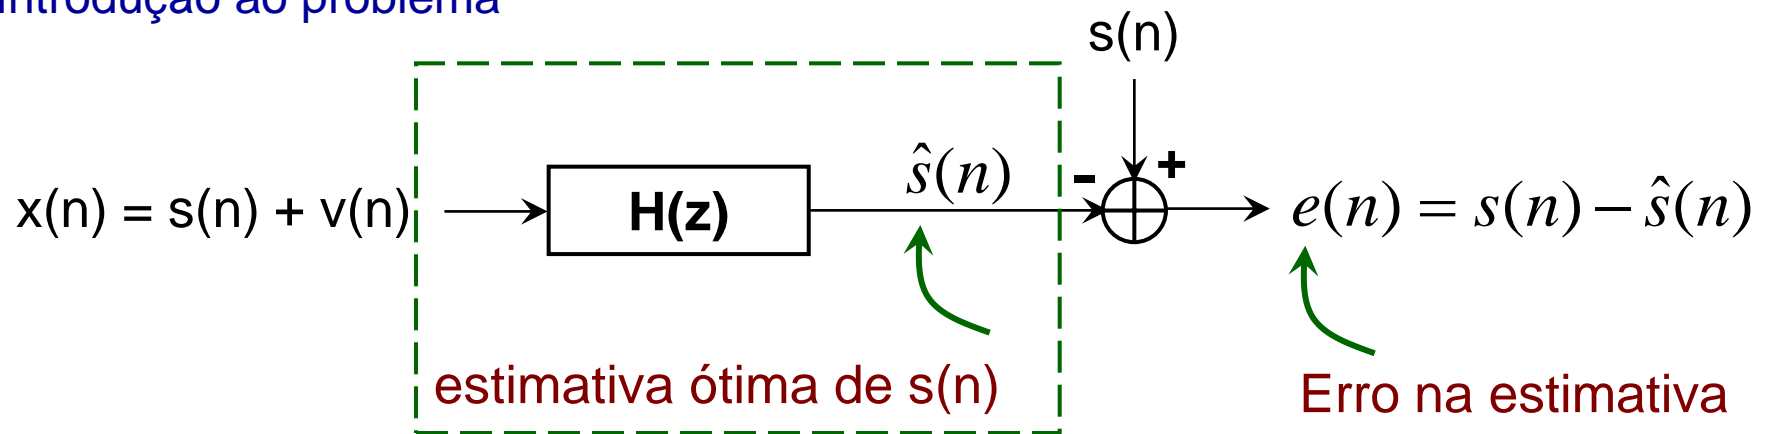
Os filtros passa baixas, etc., raramente restauram o sinal em algum sentido ótimo.

❖ Solução:

Filtros de Wiener ou então de Kalman.

Utilizam métodos dos mínimos quadrados

## 1. Introdução ao problema



### ❖ Problema:

- Projeto de um filtro com resposta ao impulso  $h(n)$  que produz uma estimativa ótima de  $s(n)$ .

### ❖ Critério:

- O erro quadrático médio entre as amostras originais e as estimadas deve ser mínimo, isto é,

$$\varepsilon = E[ e^2(n) ]_{\text{MIN}}$$

- Este critério tem a vantagem de ser simples na implementação e no tratamento matemático

## 2. Filtro de Wiener FIR

- ❖ Admitindo um filtro FIR com  $M$  coeficientes constantes, então:

$$H(z) = \sum_{l=0}^{M-1} h(l)z^{-l}$$

- ❖ Sendo  $x(n)$  o sinal de entrada, então o sinal estimado será dado pela soma convolução entre  $h(n)$  e  $x(n)$ . Assim:

$$\hat{s}(n) = \sum_{l=0}^{M-1} h(l)x(n-l)$$

- ❖ **Problema:**

- Encontrar os coeficientes  $h(k) : k = 0, 1, \dots, M-1$  tal que o erro quadrático médio seja mínimo, isto é:

$$\varepsilon = E[|e(n)|^2] = E[|s(n) - \hat{s}(n)|^2]_{\text{MÍNIMO}}$$

### 3. Cálculo dos $h(k)$

❖ Derivando  $\varepsilon$  em relação a  $h^*(k)$  tem-se:

$$\frac{\partial \varepsilon}{\partial h^*(k)} = \frac{\partial E[e(n)e^*(n)]}{\partial h^*(k)} = E\left[e(n) \frac{e^*(n)}{\partial h^*(k)}\right] = 0$$

❖ Derivada do conjugado do erro:


$$\frac{\partial e^*(n)}{\partial h^*(k)} = \frac{\partial (s(n) - \hat{s}(n))^*}{\partial h^*(k)} = x^*(n-k)$$

substituindo

❖ Para que o erro seja mínimo tem-se que:

$$E[e(n)x^*(n-k)] = 0 \quad : k = 0, 1, \dots, M-1$$

- Sinal de erro e de entrada devem ser ortogonais.
- Princípio da ortogonalidade.





➤ como: 
$$e(n) = s(n) - \hat{s}(n) = s(n) - \sum_{l=0}^{M-1} h(l)x(n-l)$$

➤ substituindo na equação anterior: 
$$E[e(n)x^*(n-k)] = 0 \quad \text{tem-se:}$$

$$E\left[s(n)x^*(n-k) - \sum_{l=0}^{M-1} h(l)x(n-l)x^*(n-k)\right] = 0$$

$$E[s(n)x^*(n-k)] - \sum_{l=0}^{M-1} h(l)E[x(n-l)x^*(n-k)] = 0$$

➤ portanto:

$$r_{sx}(k) = \sum_{l=0}^{M-1} h(l)r_x(k-l) \quad : k = 0, 1, \dots, M-1$$

Equações  
de Wiener-  
Hopf

❖ Na forma matricial:

$$\mathbf{R}_x \cdot \mathbf{h} = \mathbf{r}_{sx}$$

$$\mathbf{R}_x = \begin{bmatrix} r_x(0) & r_x(1) & \cdots & r_x(M-1) \\ r_x(1) & r_x(0) & \cdots & r_x(M-2) \\ \vdots & \vdots & \ddots & \vdots \\ r_x(M-1) & r_x(M-2) & \cdots & r_x(0) \end{bmatrix}$$

**Matriz de Toeplitz  
(hermitiana)**

$$\mathbf{x}^H = [\mathbf{X}^T]^*$$

$$\mathbf{h} = \begin{bmatrix} h(0) \\ h(1) \\ \vdots \\ h(m-1) \end{bmatrix}$$

$$\mathbf{r}_{sx} = \begin{bmatrix} r_{sx}(0) \\ r_{sx}(1) \\ \vdots \\ r_{sx}(m-1) \end{bmatrix}$$

❖ Erro mínimo:

$$\varepsilon_{MIN} = r_s(n) - \sum_{l=0}^{M-1} h(l)r_{sx}^*(l)$$

## 4. Aplicação prática

- ❖ Em muitas aplicações sinal e ruído são admitidos descorrelacionados.

$$x(n) = s(n) + v(n) \quad \Rightarrow \quad \left| \begin{array}{l} r_{sx}(k) = r_s(k) \\ \mathbf{R}_x = \mathbf{R}_s + \mathbf{R}_v \end{array} \right.$$

- ❖ e as equações de Wiener-Hopf se tornam:

$$[\mathbf{R}_s + \mathbf{R}_v] \mathbf{h} = \mathbf{r}_s$$

- ❖ Solução das equações

$$\mathbf{R}_x \cdot \mathbf{h} = \mathbf{r}_{sx} \quad \longrightarrow \quad R_x \text{ Matriz de Toeplitz (hermitiana)}$$

$$x^H = [X^T]^*$$

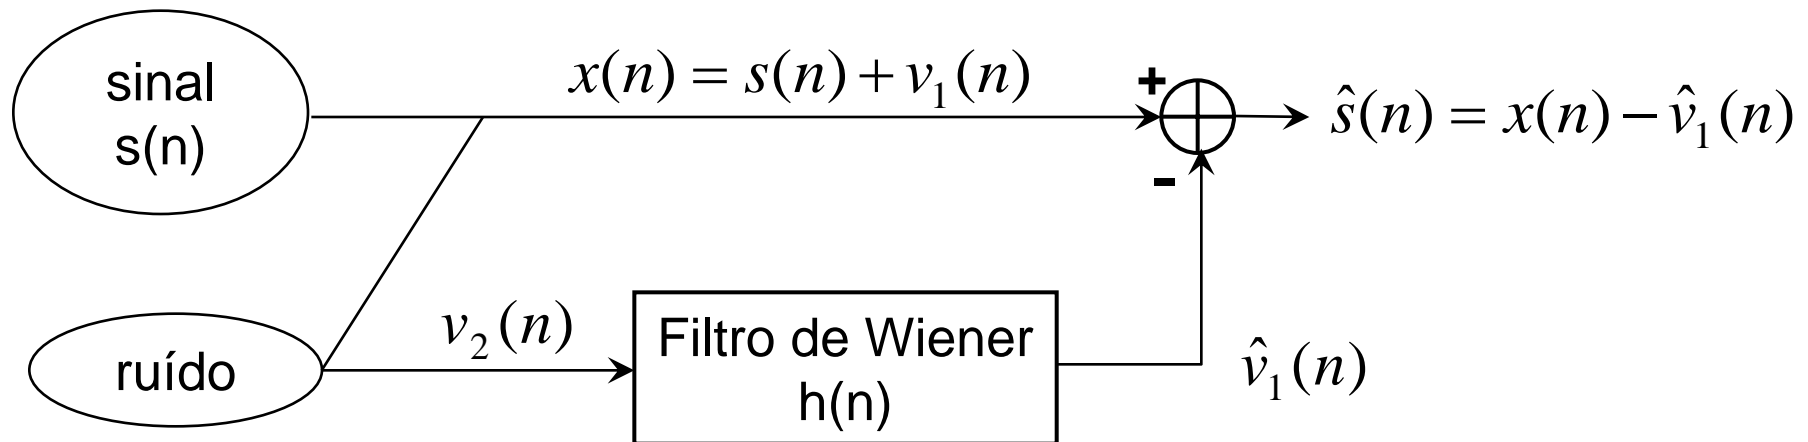
Algoritmos de Levinson  
e de Cholesky

## 5. Filtro de Wiener como supressor de ruído

- Estimação de um sinal  $s(n)$  a partir de uma medida  $x(n)$  contaminada por ruído aditivo.

$$x(n) = s(n) + v_1(n)$$

- Neste caso, as estatísticas do ruído são obtidas através de um sensor secundário como mostra a figura.
- O sinal é utilizado para estimar o ruído  $v_1(n)$ .



- Os ruídos medidos nos dois sensores são correlacionados mas não são iguais; O filtro estima  $v_1(n)$  a partir de  $v_2(n)$ .

## ❖ Obtenção das equações de Wiener-Hopf

➤ Sinal de entrada  $v_2(n)$

➤ sinal a ser estimado  $v_1(n)$

➤ equações de Wiener-Hopf:  $\Rightarrow \mathbf{R}_{v_2} \mathbf{h} = \mathbf{r}_{v_1 v_2}$

➤ Cálculo da correlação cruzada:

$$\begin{aligned} r_{v_1 v_2}(k) &= E[v_1(n)v_2^*(n-k)] = E[(x(n) - s(n))v_2^*(n-k)] \\ &= E[x(n)v_2^*(n-k)] - E[s(n)v_2^*(n-k)] \\ &= E[x(n)v_2^*(n-k)] = r_{xv_2}(k) \end{aligned}$$




➤ Portanto:  $\mathbf{R}_{v_2} \mathbf{h} = \mathbf{r}_{xv_2}$

➤ Observe que  $x(n)$  e  $v_2(n)$  são sinais disponíveis e portanto é possível uma implementação prática deste filtro.

## 5.1 Exemplo

- **Sinal desejado:**  $s(n) = \text{sen}(w_0 n + \phi)$  onde:  $w_0 = 0.1\pi$
- Os sinais de ruído foram gerados considerando um modelo AR(1):

$$\begin{cases} v_1(n) = 0.8v_1(n-1) + g(n) \\ v_2(n) = 0.6v_2(n-1) + g(n) \end{cases} \quad \text{onde } g(n) : \text{ruído branco}$$



## 6. Filtro de Wiener IIR

- Neste caso  $h(n)$  tem duração infinita.
- Tem-se disponível uma medida  $x(n)$  contaminada por ruído aditivo.

$$x(n) = s(n) + v(n)$$

- Dois tipos de filtros: causal e não causal.

### 6.1 Filtro de Wiener não causal

- Saída do filtro: 
$$\hat{s}(n) = \sum_{l=-\infty}^{\infty} h(l)x(n-l)$$

- Problema: Encontrar o filtro que minimiza o erro quadrático médio:

$$\varepsilon = E[|e(n)|^2] = E[|s(n) - \hat{s}(n)|^2]_{\text{MÍNIMO}}$$

- Solução: derivando o erro com relação aos  $h^*(k)$  tem-se que:

$$\sum_{l=-\infty}^{\infty} h(l)r_x(k-l) = r_{sx}(k) \quad : -\infty < k < \infty$$

❖ No domínio da frequência:

$$H(e^{j\omega}) = \frac{P_{sx}(e^{j\omega})}{P_x(e^{j\omega})}$$

➤ Erro quadrático médio mínimo:

$$\varepsilon_{MIN} = \frac{1}{2\pi} \int_{-\pi}^{\pi} \left[ P_s(e^{j\omega}) - H(e^{j\omega}) P_{sx}^*(e^{j\omega}) \right] d\omega = r_s(0) - \sum_{l=-\infty}^{\infty} h(l) r_{sx}^*(l)$$

➤ No caso de sinal e ruído serem descorrelacionados:

$$H(e^{j\omega}) = \frac{P_s(e^{j\omega})}{P_s(e^{j\omega}) + P_v(e^{j\omega})}$$

$P_s(e^{j\omega}) \gg P_v(e^{j\omega}) \Rightarrow H(e^{j\omega}) \approx 1$  ➡ Sinal predominante

$P_s(e^{j\omega}) \ll P_v(e^{j\omega}) \Rightarrow H(e^{j\omega}) \approx 0$  ➡ ruído predominante



## 6.2 Exemplo

➤ Sinal AR(1) com dep: 
$$P_s(z) = \frac{b_0^2}{(1 - \alpha z^{-1})(1 - \alpha z)}$$

➤ Ruído branco com variância:  $\sigma_v^2$

➤ Resposta do filtro: 
$$H(z) = \frac{b_0^2}{b_0^2 + \sigma_v^2(1 - \alpha z^{-1})(1 - \alpha z)}$$

➤ admitindo:  $b_0 = 0.5$ ;  $\alpha = 0.5$ ;  $\sigma_v^2 = 0.25$


$$H(z) = \frac{0.4688}{(1 - 0.2344 z^{-1})(1 - 0.2344 z)} \quad h(n) = 0.496 \times 0.2344^{|n|}$$

➤ Erro mínimo:  $\varepsilon_{MIN} = \sigma_v^2 h(0) = 0.124$


## Apêndice

Exemplos de filtragem de um sinal de voz


# Filtro de Kalman



# Filtro de Wiener



# Filtro de Butterworth



## Tabela Comparativa

Filtro	Aumento na SNR
Butterworth	5 dB
Wiener	8 dB
Kalman	18 dB