

## Predição Linear

Estimar uma amostra futura ou passada a partir de uma combinação linear de amostras do processo.



predição retrógrada  
retro-predição  
(backward)

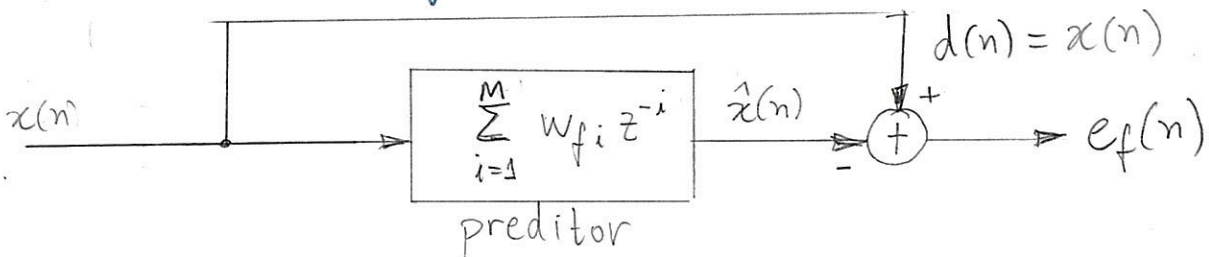
predição progressiva (forward)

Cada amostra do processo pode ser vista como sendo composta por uma parcela dependente das amostras anteriores (poterious) e outra independente, a parcela de inovação do processo.

Casos limites:

- não há parcela independente: processo determinístico
- não há parcela dependente: processo estocástico branco

## Predição Linear Progressiva a um passo



$$\hat{x}(n) = w_{f1} x(n-1) + w_{f2} x(n-2) + \dots + w_{fM} x(n-M) = \underline{w}_f^T \underline{x}(n-1)$$

Objetivo: minimizar  $E\{e_f^2(n)\}$

Observe que a formulação é equivalente à de filtro de Wiener (Wiener):

	Wiener	Preditor
entrada	$\underline{x}(n)$	$\underline{x}(n-1)$
referência	$d(n)$	$x(n)$
erro	$d(n) - \underline{w}^T \underline{x}(n)$ $\hat{d}(n)$	$x(n) - \underline{w}_f^T \underline{x}(n-1)$ $\hat{x}(n-1)$


$$\underline{w}_{\text{ótimo}} = R_x^{-1} p_{xd} \Rightarrow \underline{w}_f_{\text{ótimo}} = R_x^{-1} p_{xd} \quad \leftarrow E\{\underline{x}(n-1)\underline{x}^T(n-1)\} = E\{\underline{x}(n)\underline{x}^T(n)\}$$

$$p_{xd} = E\{\underline{x}(n-1)x(n)\} = E\left\{\begin{bmatrix} x(n-1)x(n) \\ x(n-2)x(n) \\ \vdots \\ x(n-M)x(n) \end{bmatrix}\right\} = \begin{bmatrix} r_x(1) \\ r_x(2) \\ \vdots \\ r_x(M) \end{bmatrix} = \underline{r}_x$$

$$\therefore \underline{w}_f_{\text{ótimo}} = R_x^{-1} \underline{r}_x$$

## Filtro de Erro de Predição (passo unitário) (FEP)

Se imaginarmos um sistema cuja entrada é  $x(n)$  e a saída é o erro de predição, temos:



$$e_f(n) = x(n) - \hat{x}(n) = x(n) - \underline{w}_f^T \underline{x}(n+1) = x(n) - \sum_{i=1}^M w_{fi} x(n-i)$$

$$A(z) = 1 - \sum_{i=1}^M w_{fi} z^{-i} \Rightarrow \text{função de transferência do filtro de erro de predição}$$

$$e_f(n) = \begin{bmatrix} 1 \\ -w_{f1} \\ -w_{f2} \\ \vdots \\ -w_{fM} \end{bmatrix}^T \cdot \begin{bmatrix} x(n) \\ x(n-1) \\ x(n-2) \\ \vdots \\ x(n-M) \end{bmatrix} = \begin{bmatrix} 1 \\ -w_f \end{bmatrix}^T \cdot \underline{x}(n)$$

O FEP pode ser visto como um filtro de eliminação de redundância entre as amostras de  $x(n)$ .

### Propriedades:

i) Os coeficientes ótimos do preditor são tais que  $\frac{\partial E\{e_f^2(n)\}}{\partial w_{fi}} = 0$

$$\forall i$$
$$\frac{\partial E\{e_f^2(n)\}}{\partial w_{fi}} = 2 E \left\{ e_f(n) \cdot \frac{\partial e_f(n)}{\partial w_{fi}} \right\} = 2 E \left\{ e_f(n) \cdot \frac{\partial \left[ x(n) - \sum_{i=1}^M w_{fi} x(n-i) \right]}{\partial w_{fi}} \right\} =$$

$$= 2 E \{ e_f(n) [-x(n-i)] \} \Rightarrow E \{ e_f(n) x(n-i) \} = 0 \quad p/ i=1,2,\dots,M$$

Quando  $M \rightarrow \infty$ , o FEP produz um sinal ortogonal às amostras passadas da entrada.

$$E \{ e_f(n) e_f(n-k) \} = E \{ e_f(n) [x(n-k) - \sum_{i=1}^M w_{fi} x(n-k-i)] \} = \sum_{i=0}^M a_i E \{ e_f(n) x(n-(k+i)) \}$$

$$\underline{a} = \begin{bmatrix} 1 \\ -\underline{w}_f^T \end{bmatrix}$$

$$= a_0 E \{ e_f(n) x(n-k) \} + a_1 E \{ e_f(n) x(n-(k+1)) \} + \dots + a_M E \{ e_f(n) x(n-(k+M)) \}$$

Mas, quando  $M \rightarrow \infty$ ,  $E \{ e_f(n) x(n-j) \} = 0$  se  $j \neq 0$

$$\therefore E \{ e_f(n) e_f(n-k) \} = \begin{cases} E \{ e_f^2(n) \} = J_{\min} = r_x(0) - \underline{w}_f^T \underline{r}_x, & k=0 \\ 0, & k \neq 0, \dots, M \end{cases}$$

Portanto, o FEP é um filtro branqueador pois sua saída tende a ser ortogonal à medida que  $M$  aumenta. No limite, quando  $M \rightarrow \infty$ , a saída do FEP é branca.

ii) Seja  $A(z) = \sum_{k=0}^M a_k z^{-k}$  a função de transferência de um FEP e  $\alpha_i, i=1, \dots, M$  os zeros de  $A(z)$ . Podemos então escrever:

$$A(z) = B(z) (1 - \alpha_b z^{-1}), \text{ onde } \alpha_b \text{ é um dos zeros de } A(z)$$

$$\text{e } B(z) = \prod_{\substack{i=1 \\ i \neq b}}^M (1 - \alpha_i z^{-1})$$

O MSE pode ser escrito da seguinte forma:

$$E \{ |e_f^-(n)|^2 \} = \frac{1}{2\pi} \int_{-\pi}^{\pi} S_f(e^{j\omega}) d\omega \rightarrow \text{a área da densidade espectral de potência fornece a potência ou a variância do sinal.}$$

$$E \{ |e_f(n)|^2 \} = \frac{1}{2\pi} \int_{-\pi}^{\pi} S_x(e^{j\omega}) \cdot |A(e^{j\omega})|^2 d\omega$$

resposta em frequência do FEP

Mas  $A(e^{j\omega}) = B(e^{j\omega}) (1 - \alpha_b e^{-j\omega})$ . Então

$$E \{ |e_f(n)|^2 \} = \frac{1}{2\pi} \int_{-\pi}^{\pi} S_x(e^{j\omega}) |B(e^{j\omega})|^2 \cdot |1 - \alpha_b e^{-j\omega}|^2 d\omega$$

Expandindo o zero  $\alpha_b$  em sua forma polar,  $\alpha_b = \rho_b e^{j\omega_b}$ ,

$$E \{ |e_f(n)|^2 \} = \frac{1}{2\pi} \int_{-\pi}^{\pi} S_x(e^{j\omega}) |B(e^{j\omega})|^2 \cdot (1 - 2\rho_b \cos(\omega - \omega_b) + \rho_b^2) d\omega$$

Vamos supor que todos os parâmetros do filtro já tenham sido otimizados, exceto o módulo do "último zero",  $\rho_b$ .

Nesse caso, o valor ótimo de  $\rho_b$  é obtido por  $\frac{\partial E \{ |e_f(n)|^2 \}}{\partial \rho_b} = 0$

$$\frac{\partial E \{ |e_f(n)|^2 \}}{\partial \rho_b} = \frac{1}{2\pi} \int_{-\pi}^{\pi} S_x(e^{j\omega}) |B(e^{j\omega})|^2 \cdot 2(\rho_b - \cos(\omega - \omega_b)) d\omega = 0$$

$\downarrow \qquad \downarrow$   
 $\geq 0 \qquad \geq 0$

A única forma de anular o integral é se  $\rho_b - \cos(\omega - \omega_b)$  assumir valores positivos e negativos.

Como  $|\cos(\omega - \omega_b)| \leq 1$  e  $\rho_b \geq 0$ ,  $\rho_b < 1$  para que existam valores negativos de  $\rho_b - \cos(\omega - \omega_b)$

Esse procedimento pode ser repetido para qualquer zero do FEP, o que nos leva a concluir que todos os seus zeros têm módulo inferior a 1.

Como o FEP tem seus polos na origem e todos os seus zeros estão dentro da circunferência de raio unitário, o FEP é um sistema de fase mínima.

iii) O FEP ótimo pode ser obtido através da solução de um problema de minimização de variância com restrições lineares (LCMV):

$$e_f(n) = \underline{a}^H \underline{x}(n)$$

$$\min E \{ |e_f(n)|^2 \} = \underline{a}^H R_x \underline{a}$$

$$\text{s.a. } \underline{c}^H \underline{a} = \underline{g}$$

no qual

$$\underline{c} = [1 \ 0 \ 0 \ \dots \ 0]^T$$

$$\underline{a} = [a_0 \ -a_1 \ -a_2 \ \dots \ a_M]^T$$


$$\underline{g} = 1$$

Neste caso, a solução ótima é dada por

$$\left( \underline{w}_0 = R_x^{-1} C (C^H R_x^{-1} C)^{-1} \underline{g} \right)$$

$$\underline{a} = \frac{R_x^{-1} \underline{c}}{\underline{c}^T R_x^{-1} \underline{c}}$$

iv) Imagine que se deseja estimar um processo  $s(n)$ , WSS, com média nula, variância  $\sigma_s^2$  e composto por amostras i.i.d. (branco)



$$x(n) = \sum_{i=0}^{\infty} h_i s(n-i) + \eta(n)$$

$$\underline{W}_{\text{Wiener}} = R_x^{-1} p_{xs} = R_x^{-1} \cdot \begin{bmatrix} h_0 \sigma_s^2 \\ 0 \\ \vdots \\ 0 \end{bmatrix}$$

$$\frac{\underline{W}_{\text{Wiener}}}{h_0 \sigma_s^2} = R_x^{-1} \cdot \begin{bmatrix} 1 \\ 0 \\ \vdots \\ 0 \end{bmatrix} = R_x^{-1} \underline{c}$$


Substituindo na expressão do FEP ótimo:

$$\underline{a} = \frac{\frac{\underline{W}_{\text{Wiener}}}{h_0 \sigma_s^2}}{c^T \frac{\underline{W}_{\text{Wiener}}}{h_0 \sigma_s^2}} \Rightarrow \boxed{\underline{a} = \frac{1}{W_{0\text{Wiener}}} \cdot \underline{W}_{\text{Wiener}}}$$

Portanto, em um problema de desconvolução de um processo branco, o FEP ótimo corresponde ao filtro de Wiener normalizado pelo seu primeiro coeficiente.

★ É possível estimar o sinal  $s(n)$  de maneira não-supervisionada utilizando-se um FEP.

Exemplo: Equalização de canais de comunicações



i.i.d  
 $\{-1, +1\}$   
 equiprobáveis

$$x(n) = h_0 s(n) + h_1 s(n-1) + h_2 s(n-2) + \dots + h_{N-1} s(n-N+1) + \eta(n)$$

$$x(n-1) = h_0 s(n-1) + h_1 s(n-2) + \dots + h_{N-1} s(n-N) + \eta(n-1)$$

$$\vdots$$

$$x(n-M) = h_0 s(n-M) + h_1 s(n-M-1) + \dots + h_{N-1} s(n-M-N+1) + \eta(n-M)$$

O erro de predição progressivo a passo unitário é dado por:

$$e_f(n) = x(n) - w_{f1} x(n-1) - w_{f2} x(n-2) - \dots - w_{fM} x(n-M)$$

Note que a única informação de  $s(n)$  presente em  $x(n)$  é a amostra mais recente do sinal transmitido, ou seja,  $s(n)$ .  
 A informação presente em  $x(n)$  é ausente em  $x(n-1)$ ,  $x(n-2)$ , ...,  $x(n-M)$ .

Neste caso, o FEP consegue remover toda a redundância existente entre  $x(n)$  e  $x(n-1)$  o erro de predição residual seria

$$e(n) = h_0 s(n) + \eta'(n)$$



$$H(z) = 1 + 0,5z^{-1}$$

Exemplo

$$\Rightarrow \text{zero em } z = -0,5$$

$$\sigma_n^2 = 0,1$$

Solução de Wiener para atraso 0 ( $d(n) = s(n)$ ), com equalizador de 2º ordem:

$$\underline{w}_w = R_x^{-1} p_{xd} \Rightarrow \begin{bmatrix} w_0 \\ w_1 \\ w_2 \end{bmatrix} = \begin{bmatrix} 1,25 + \sigma_n^2 & 0,5 & 0 \\ 0,5 & 1,25 + \sigma_n^2 & 0,5 \\ 0 & 0,5 & 1,25 + \sigma_n^2 \end{bmatrix}^{-1} \begin{bmatrix} 1 \\ 0 \\ 0 \end{bmatrix} = \begin{bmatrix} 0,881 \\ -0,378 \\ 0,14 \end{bmatrix}$$

$$W(z) = 0,881 - 0,378z^{-1} + 0,14z^{-2}$$

FEP ótimo de 2º ordem:  $A(z) = 1 - w_{f1}z^{-1} - w_{f2}z^{-2}$

$$\underline{w}_f = R_x^{-1} r_x \Rightarrow \begin{bmatrix} w_{f1} \\ w_{f2} \end{bmatrix} = \begin{bmatrix} 1,35 & 0,5 \\ 0,5 & 1,35 \end{bmatrix}^{-1} \begin{bmatrix} 0,5 \\ 0 \end{bmatrix} = \begin{bmatrix} 0,429 \\ -0,159 \end{bmatrix}$$

$$\underline{a} = \begin{bmatrix} 1 \\ -0,429 \\ +0,159 \end{bmatrix} \quad \text{ou} \quad A(z) = 1 - 0,429z^{-1} + 0,159z^{-2}$$

zeros de  $W(z)$ :  $z_1 = 0,215 + j0,336$  e  $z_2 = 0,215 - j0,336$

zeros de  $A(z)$ :  $z_1 = 0,215 + j0,336$  e  $z_2 = 0,215 - j0,336$


$$\frac{w_w}{w_0} \Rightarrow \begin{bmatrix} 1 \\ -0,429 \\ 0,159 \end{bmatrix} = \underline{a}$$

Resposta combinada canal - equalizador:

$$h^* H(z) W(z) = 0,881 + 0,062z^{-1} - 0,049z^{-2} + 0,070z^{-3}$$


$$H(z) A(z) = 1 - 0,071z^{-1} - 0,051z^{-2} + 0,079z^{-3}$$

# Imageamento Sísmico



Domínio de profundidade

camadas



impedância acústica



coeficientes de reflexão



funções de refletividade



$r(n)$

Domínio Temporal.

\* fonte



+ ruído




= traço



$w(n)$


$\eta(n)$

$t(n)$



# Predição Linear e Análise de Sinais.

## a) Predição de um sinal AR




↳ estável (todos os pólos dentro de CRV)

- Se  $M < L$ ,  $e_f(n)$  é correlacionado pois não há zeros suficientes para cancelar os pólos em  $B(z)$ .


- Se  $M = L$ ,  $w_{fi} = b_i$  e  $e_f(n) = v(n)$ , os zeros cancelam os pólos.

- Se  $M > L$ ,  $w_{fi} = b_i$  para  $i = 1, 2, \dots, L$  e  $w_{fi} = 0$  para  $i = L+1, \dots, M$ .

A predição linear pode ser usada como um método de análise de um sinal aleatório que presume que o sinal se comporta como um modelo auto-regressivo.




é chamado de filtro de síntese pois gera um processo AR a partir de um ruído branco.



é chamado de filtro de análise pois a partir dele é possível identificar o processo AR que gera  $x(n)$ .


No processo de identificação do processo AR, a ordem  $M$  do FEP deve ser aumentada até o erro quadrático médio de predição parar de diminuir. Nessa situação,  $e_f(n)$  é branco



Caso essa condição não ocorra, o sinal  $x(n)$  não é gerado por um modelo AR e o FEP constitui uma aproximação AR do sistema original. Nesses casos, qto maior  $M$ , mais  $e_f(n)$  tende a um ruído branco.

b) Predição de um sinal composto por raios espectrais

Comencemos analisando um exemplo simples:  $x(n) = 1 + v(n)$   
 $\downarrow$   
 branco,  $\sigma_v^2$



$$\text{FEP: } A(z) = 1 - \omega_{f1} z^{-1}$$

$$\text{Preditor \acute{o}timo: } \omega_{f1} = \frac{\Gamma_x(1)}{\Gamma_x(0)} = \frac{E\{x(n)x(n-1)\}}{E\{x(n)x(n)\}} = \frac{E\{(1+v(n))(1+v(n-1))\}}{E\{(1+v(n))^2\}} = \frac{1}{1 + \sigma_v^2}$$

$$\text{Assim; } A(z) = 1 - \left(\frac{1}{1 + \sigma_v^2}\right) z^{-1}$$

Se  $\sigma_v^2 = 0$ ,  $x(n)$  é uma constante: apenas uma amostra é necessária para prever o sinal com erro nulo. Nesse caso,  $A(z) = 1 - z^{-1}$  possui um zero no círculo de raio unitário, que indica que na frequência  $2k\pi$  o FEP

À medida que  $\sigma_v^2$  aumenta,  $\omega_{f1}$  diminui e o zero caminha na direção da origem. Quando  $\sigma_v^2 \rightarrow \infty$ ,  $A(z) = 1$ , ou seja, o erro de predição é o próprio sinal  $x(n)$ .

Suponha agora que  $x(n) = \sqrt{2} \cos(n\omega_0 + \varphi) + v(n)$ , em que  $\varphi$  é uma v.a. uniforme  $\in (0, 2\pi)$




FEP:  $A(z) = 1 - \omega_{f1} z^{-1} - \omega_{f2} z^{-2}$

Coefficientes otimizados:  $\omega_{f1} = 2 \cos \omega_0 \frac{\sin^2 \omega_0 + \sigma_v^2 / 2}{\sin^2 \omega_0 + \sigma_v^2 (2 + \sigma_v^2)}$

$$\omega_{f2} = -1 + \frac{\sigma_v^2 (1 + \sigma_v^2 + 2 \cos^2 \omega_0)}{(1 + \sigma_v^2)^2 - \cos^2 \omega_0}$$

- Se  $\sigma_v^2 = 0 \Rightarrow \omega_{f1} = 2 \cos \omega_0$  e  $\omega_{f2} = -1$

Nesse caso,  $A(z) = 1 - 2 \cos \omega_0 z^{-1} + z^{-2}$ , cujas raízes são  $z_1 = e^{-j\omega_0}$  e  $z_2 = e^{j\omega_0}$



O FEP anula perfeitamente as raízes presentes no sinal de entrada


Densidade espectral de potência de  $\sqrt{2} \cos(\omega_0 n + \varphi)$

Vimos anteriormente que podemos expressar o MSE de predição como:

$$E\{|e_f(n)|^2\} = \frac{1}{2\pi} \int_{-\pi}^{\pi} S_x(e^{j\omega}) |B(e^{j\omega})|^2 (1 - 2\beta_b \cos(\omega - \omega_b) + \beta_b^2) d\omega$$

• Se  $\alpha_b$  é um zero na CRU,  $\beta_b = 1$

• O termo  $(1 - 2\beta_b \cos(\omega - \omega_b) + \beta_b^2) = 2 - 2\cos(\omega - \omega_b)$  só se anula em  $\omega = \omega_b$ . A integral, ou seja,  $E\{|e_f(n)|^2\}$ , só se anula se  $S_x(e^{j\omega})$  for composto de raios espectrais situados exatamente em  $|\omega| = \omega_b$ :




Observação:

\* O FEP funciona como um dispositivo de análise do sinal de entrada  $x(n)$ . Se  $x(n)$  tiver um espectro discreto (composto de raios), então, caso tenha ordem suficiente, o FEP terá todos os seus zeros sobre o CRU (Círculo de Raio Unitário) nas frequências (ângulos) densas raios. Nesse caso o erro é nulo e  $x(n)$  é dito predizível. Se, por outro lado,  $x(n)$  possuir um espectro contínuo para  $\omega \in (-\pi, \pi)$ , então, caso tenha ordem suficiente, o preditor irá branquear o sinal. Nesse caso,  $x(n)$  é dito um sinal regular.

\* Em qualquer caso de  $x(n)$  regular, o FEP sempre analisa o sinal pelo método, i.e., segundo a hipótese, do modelo AR, mas somente quando de fato  $x(n)$  for um processo AR é que ele conseguirá branquear.

# Predição Retrógrada de passo unitário



A predição retrógrada linear consiste de estimar um valor passado do processo  $x(n)$  a partir de uma combinação linear de amostras mais recentes do processo. No caso específico de passo de predição unitário, deseja-se uma estimativa de  $x(n-M)$  a partir de  $x(n), x(n-1), \dots, x(n-M+1)$ :

$$\hat{x}(n-M) = \underline{w}_b^T \underline{x}(n)$$

em que:

$$\underline{x}(n) = [x(n) \quad x(n-1) \quad \dots \quad x(n-M+1)]^T$$

$$\underline{w}_b = [w_{b0} \quad w_{b1} \quad \dots \quad w_{bM-1}]^T$$

O erro de predição retrógrada é dado por

$$e_b(n) = x(n-M) - \hat{x}(n-M) \Rightarrow e_b(n) = x(n-M) - \underline{w}_b^T \underline{x}(n)$$

Minimizando  $E\{|e_b(n)|^2\}$ , caímos no mesmo cenário de filtragem ótima com  $d(n) = x(n-M)$ . Então:

$$\underline{w}_{b \text{ ótimo}} = R_x^{-1} r_x^B, \text{ em que}$$

$$r_x^B = E\{\underline{x}(n) x(n-M)\} = \begin{bmatrix} r_x(n) \\ r_x(n-1) \\ \vdots \\ r_x(1) \end{bmatrix}$$

Nota que  $\underline{w}_f = \begin{bmatrix} 0 & \dots & 0 & 1 \\ 0 & \dots & 1 & 0 \\ \vdots & & & \vdots \end{bmatrix} \cdot \underline{w}_b$

# Filtro de Erro de Predição Retrogrado de passo unitário


$$e_b(n) = x(n-M) - \sum_{i=0}^{M-1} w_{bi} x(n-i) = \sum_{i=0}^M \mu_i x(n-i)$$

em que: 
$$\mu_i = \begin{cases} -w_{bi}, & i=0, 1, \dots, M-1 \\ 1, & i=M \end{cases}$$

$$e_b(n) = \underline{\mu}^T \underline{x}(n), \text{ onde } \underline{x}(n) = [x(n) \ x(n-1) \ \dots \ x(n-M)]^T$$
  
$$\underline{\mu} = [-w_b^T \ 1]^T$$

Função de transferência:

$$U(z) = \sum_{i=0}^M \mu_i z^{-i} = \left( \sum_{i=0}^{M-1} -w_{bi} z^{-i} \right) + z^{-M}$$



## Propriedades

- i) O FEP retrogrado de passo unitário é um filtro brunquado
- ii) Os zeros do FEP retrogrado têm módulo maior ou igual à unidade, ou seja, é um filtro de fase-máxima
- iii) Formulando a otimização do FEP retrogrado como um problema de minimização de variância com restrições lineares, temos:




$$\min E\{|e_b(n)|^2\} = \underline{u}^H R_x \underline{u}$$

$$\text{s.a. } u_M = 1 \Rightarrow \underbrace{[0 \ 0 \ \dots \ 0 \ 1]^T}_{\underline{c}} \underline{u} = 1$$

$$\underline{u} = \frac{R_x^{-1} \underline{c}}{\underline{c}^T R_x^{-1} \underline{c}} \quad \text{com } \underline{u} = \begin{bmatrix} -w_{b0} \\ -w_{b1} \\ \vdots \\ -w_{bM-1} \\ 1 \end{bmatrix} \quad \underline{x(n)} = \begin{bmatrix} x(n) \\ x(n-1) \\ \vdots \\ x(n-M) \end{bmatrix}$$

Imagine que se deseja estimar um processo  $s(n)$ , WSS, com média nula, variância  $\sigma_s^2$  e composto por amostras i.i.d. (processo branco)



$$x(n) = \sum_{i=0}^{N-1} h_i s(n-i) + \eta(n)$$

Estimar  $s(n)$  com atraso máximo a partir de  $\underline{x(n)} = [x(n) \ x(n-1) \ \dots \ x(n-M)]^T$

$$\underline{x(n-M)} = h_0 s(n-M) + \dots + h_{N-1} s(n-M-N+1) + \eta(n-M)$$

atraso máximo  $(M+N-1)$

$$\underline{d(n)} = s(n - (M+N-1))$$

$$\underline{W}_w = R_x^{-1} p_{xd} = R_x^{-1} E\{\underline{x(n)} s(n - (M+N-1))\} = R_x^{-1} \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 0 \\ h_{N-1} \sigma_s^2 \end{bmatrix} = R_x^{-1} \underline{c} \cdot h_{N-1} \sigma_s^2$$

$$\text{com } \underline{x(n)} = [x(n) \ x(n-1) \ \dots \ x(n-M)]^T$$

$$\underline{W}_w = [W_{w0} \ W_{w1} \ \dots \ W_{wM}]^T$$

$$\underline{R}_x^{-1} \underline{c} = \frac{\underline{W}_w}{1 \dots \sigma_s^2}$$

Substituindo na expressão dos coeficientes ótimos do FEP:

$$\underline{\mu} = \frac{\frac{W_w}{h_{N-1}\sigma_s^2}}{\frac{C^T W_w}{h_{N-1}\sigma_s^2}} \Rightarrow \boxed{\underline{\mu} = \frac{W_w}{W_{wM}}}$$

Portanto, o FEP retrogrado de passo unitário é equivalente ao filtro de Wiener de <sup>ordem máxima de</sup> mesma ordem, normalizado pelo seu último coeficiente. Isso significa que o FEP realiza uma estimação não-supervisionada de  $s(n-(M+N-1))$  com um fator de escala  $\frac{1}{W_{wM}}$ .

Relação entre o MMSE retrogrado e MMSE progressivo

MMSE Wiener:  $J_{\min} = \sigma_d^2 - \underline{w}^T \underline{p}_{xd} = \sigma_d^2 - \underline{p}_{xd}^T \underline{w}$

MMSE predição progressiva: ( $d(n) = x(n)$ )

$$E\{|e_f(n)|^2\} = r_x(0) - \underline{r}_x^T \underline{w}_f = P$$

MMSE predição retrograda: ( $d(n) = x(n-M)$ )

$$E\{|e_b(n)|^2\} = r_x(0) - (\underline{r}_x^B)^T \underline{w}_b = r_x(0) - \begin{bmatrix} r_x(M) \\ \vdots \\ r_x(1) \end{bmatrix}^T \underbrace{\begin{bmatrix} w_{b0} \\ \vdots \\ w_{bM-1} \end{bmatrix}}_{\begin{bmatrix} 0 & \dots & 1 \\ 1 & \dots & 0 \end{bmatrix} \underline{w}_f} = r_x(0) - \begin{bmatrix} r_x(1) \\ \vdots \\ r_x(M) \end{bmatrix}^T \underbrace{\begin{bmatrix} w_{bM-1} \\ \vdots \\ w_{b0} \end{bmatrix}}_{\underline{w}_f}$$

$$= r_x(0) - \underline{r}_x^T \underline{w}_f = P$$

Portanto, o MMSE retrogrado e o MMSE progressivo têm o mesmo valor para preditores de mesma ordem.

# Algoritmo de Levinson-Durbin

Trata-se de um método para computar os coeficientes do FEP e a potência do erro de predição, o qual resolve as equações de Yule-Walker de maneira recursiva, tirando proveito da estrutura Toeplitz da matriz de autocorrelação  $R_x$ .

O algoritmo apresenta ordem de complexidade proporcional ao quadrado da ordem da matriz de autocorrelação. Algoritmos gerais de resolução de sistemas de equações lineares, como o método de eliminação de Gauss-Jordan, apresentam ordem de complexidade proporcional ao cubo da ordem da matriz de autocorrelação.

IDEIA: Obter o preditor ótimo de  $M$  coeficientes a partir do preditor ótimo de  $M-1$  coeficientes.

Ponto de partida:

- A solução do preditor progressivo ótimo satisfaz as equações de Wiener-Hopf para o caso em que  $d(n) = x(n)$ . Isto significa que

$$R_x^{(m)} \underline{w}_f^{(m)} = \underline{r}_x^{(m)} \rightarrow \underline{r}_x^{(m)} = \begin{bmatrix} r_x(1) \\ r_x(2) \\ \vdots \\ r_x(m) \end{bmatrix}$$

(O índice  $(m)$  denota a ordem das entidades envolvidas.)

- O MMSE do preditor é exatamente o valor do MSE avaliado na solução ótima (Wiener). No tópico anterior, vimos que

$$J_{\min} = \sigma_d^2 - \underline{w}_f^T \underline{p}_x d$$

No contexto de predição ( $d(n) = x(n)$ ),  $E\{|e_f^{(m)}|^2\} = P_m = r_x(0) - (\underline{r}_x^{(m)})^T \underline{w}_f^{(m)}$

Podemos combinar as equações de Wiener-Hopf e a equação de MMSE de predição em um único sistema:

$$(1) \begin{bmatrix} r_x(0) & (\underline{r}_x^{(m-1)})^T \\ \underline{r}_x^{(m-1)} & R_x^{(m-1)} \end{bmatrix} \begin{bmatrix} 1 \\ -\underline{w}_f^{(m-1)} \end{bmatrix} = \begin{bmatrix} P_{m-1} \\ \underline{0}^{(m-1)} \end{bmatrix}$$

Que é equivalente a  $R_x^{(m)} \cdot \begin{bmatrix} 1 \\ -\underline{w}_f^{(m-1)} \end{bmatrix} = \begin{bmatrix} P_{m-1} \\ \underline{0}^{(m-1)} \end{bmatrix}$

Acrescentando mais uma equação ao sistema, temos a matriz aumentada:

$$(2) \begin{bmatrix} R_x^{(m)} & \underline{r}_{x_B}^{(m)} \\ (\underline{r}_{x_B}^{(m)})^T & r_x(0) \end{bmatrix} \begin{bmatrix} 1 \\ -\underline{w}_f^{(m-1)} \\ 0 \end{bmatrix} = \begin{bmatrix} P_{m-1} \\ \underline{0}^{(m-1)} \\ \Delta_m \end{bmatrix} \Rightarrow R_x^{(m+1)} \begin{bmatrix} 1 \\ -\underline{w}_f^{(m-1)} \\ 0 \end{bmatrix} = \begin{bmatrix} P_{m-1} \\ \underline{0}^{(m-1)} \\ \Delta_m \end{bmatrix}$$

em que:

$$\underline{r}_{x_B}^{(m)} = [r_x(m) \quad r_x(m-1) \quad \dots \quad r_x(1)]^T$$

$$\Delta_m = (\underline{r}_{x_B}^{(m)})^T \begin{bmatrix} 1 \\ -\underline{w}_f^{(m-1)} \end{bmatrix} \quad (3)$$

Seguindo o mesmo raciocínio, é possível chegar aos seguintes resultados para o preditor retrogrado de passo unitário:

$$(4) \underbrace{\begin{bmatrix} R_x^{(m-1)} & \underline{r}_{x_B}^{(m-1)} \\ (\underline{r}_{x_B}^{(m-1)})^T & r_x(0) \end{bmatrix}}_{R_x^{(m)}} \begin{bmatrix} -\underline{w}_b^{(m-1)} \\ 1 \end{bmatrix} = \begin{bmatrix} \underline{0}^{(m-1)} \\ P_{m-1} \end{bmatrix}$$

$$R_x^{(m)} \cdot \begin{bmatrix} -\underline{w}_b^{(m-1)} \\ 1 \end{bmatrix} = \begin{bmatrix} \underline{0}^{(m-1)} \\ P_{m-1} \end{bmatrix}$$

$$(5) \begin{bmatrix} r_x(0) & (r_x^m)^T \\ r_x^m & R_x^{(m)} \end{bmatrix} \begin{bmatrix} 0 \\ -w_b^{(m-1)} \\ 1 \end{bmatrix} = \begin{bmatrix} -\Delta m \\ 0^{(m-1)} \\ P_{m-1} \end{bmatrix} \Rightarrow R_x^{(m+1)} \begin{bmatrix} 0 \\ -w_b^{(m-1)} \\ 1 \end{bmatrix} = \begin{bmatrix} \Delta m \\ 0 \\ P_{m-1} \end{bmatrix}$$

Multiplicando a equação (5) por  $k_m \triangleq \frac{\Delta m}{P_{m-1}}$

$$(6) R_x^{(m+1)} \begin{bmatrix} 0 \\ k_m \begin{bmatrix} -w_b^{(m-1)} \\ 1 \end{bmatrix} \end{bmatrix} = \begin{bmatrix} k_m^2 \cdot P_{m-1} \\ 0^{(m-1)} \\ \Delta m \end{bmatrix}$$

Fazendo (2)-(6):

$$(7) R_x^{(m+1)} \begin{bmatrix} 1 \\ -w_f^{(m-1)} + k_m w_b^{(m-1)} \\ -k_m \end{bmatrix} = \begin{bmatrix} (1 - k_m^2) P_{m-1} \\ 0^{(m-1)} \\ 0 \end{bmatrix}$$

Pegando a equação (1) para a ordem  $(m+1)$ , temos  $R_x^{(m+1)} \begin{bmatrix} 1 \\ -w_f^{(m)} \end{bmatrix} = \begin{bmatrix} P_m \\ 0 \end{bmatrix}$ .

Iguando termo a termo com a equação (7), chegamos a:

$$(8) w_f^{(m)} = \begin{bmatrix} w_f^{(m-1)} \\ 0 \end{bmatrix} - k_m \begin{bmatrix} w_b^{(m-1)} \\ -1 \end{bmatrix}$$

$$(9) P_m = (1 - k_m^2) P_{m-1}$$

Como  $w_b^{(m-1)} = \begin{bmatrix} 0 & \dots & 0 & 1 \\ \vdots & & \ddots & \vdots \\ 1 & 0 & \dots & 0 \end{bmatrix} w_f^{(m-1)}$ , podemos abrir a equação (8) na forma escalar:

$$w_{f,i}^{(m)} = \begin{cases} w_{f,i}^{(m-1)} - k_m w_{f,i}^{(m-1)}, & i = 1, \dots, m-1 \\ k_m, & i = m \end{cases}$$

Finalmente, pegando a 1ª linha da equação (6):

$$\begin{bmatrix} r_x(0) & \dots & r_x(m) \end{bmatrix} \cdot \begin{bmatrix} 0 \\ k_m \begin{bmatrix} -w_{f1}^{(m-1)} \\ \vdots \\ 1 \end{bmatrix} \end{bmatrix} = k_m^2 P_{m-1}$$

$$-k_m r_x(1) w_{f1}^{(m-1)} - k_m r_x(2) w_{f2}^{(m-1)} - \dots - k_m r_x(m-1) w_{f1}^{(m-1)} + k_m r_x(m) = k_m^2 P_{m-1}$$

Logo:

$$k_m = \frac{1}{P_{m-1}} \left[ r_x(m) - \sum_{i=1}^{m-1} w_{fi}^{(m-1)} r_x(m-i) \right] \quad (11)$$

Estabelecidas estas relações, podemos apresentar o algoritmo de Levinson-Durbin:

Entradas: elementos de autocorrelação  $r_x(0), r_x(1), \dots, r_x(M)$

Condição inicial:  $P_0 = E \{ |e_f^o(n)|^2 \} = r_x(0)$

Para  $m = 1, 2, \dots, M$ , faça:

$$1) k_m = \frac{1}{P_{m-1}} \left[ r_x(m) - \underbrace{\sum_{i=1}^{m-1} w_{fi}^{(m-1)} r_x(m-i)}_{\substack{\text{na primeira iteração este termo} \\ \text{é nulo}}} \right]$$

$$2) w_{fi}^m = \begin{cases} w_{fi}^{(m-1)} - k_m w_{f(m-i)}^{(m-1)}, & \forall i = 1, 2, \dots, m-1 \\ k_m, & \forall i = m \end{cases}$$

$$3) P_m = P_{m-1} (1 - k_m^2) \quad (|k_m| \leq 1)$$

Após término da M-ésima iteração, obtenha o preditor progressivo de ordem M,  $\underline{w}_f^{(m)} = [w_{f1} \ w_{f2} \ \dots \ w_{fM}]^T$

O preditor retrogrado pode ser obtido fazendo-se:  $\underline{w}_b^{(m)} = [w_{fm} \ w_{fM-1} \ \dots \ w_{f1}]^T$

# Predição Linear em Treliza

Erro de predição progressiva a passo unitário:

$$e_f^{(m)}(n) = x(n) - \left( \underline{w}_f^{(m)} \right)^T \underline{x}^{(m)}(n-1) \quad (12)$$

Erro de predição retrógrada a passo unitário:

$$e_b^{(m)}(n) = x(n-m) - \left( \underline{w}_b^{(m)} \right)^T \underline{x}^{(m)}(n) \quad (13)$$

Rescrevendo a equação (8) para ordem  $m+1$ :

$$\underline{w}_f^{(m+1)} = \begin{bmatrix} \underline{w}_f^{(m)} \\ 0 \end{bmatrix} - k_{m+1} \begin{bmatrix} \underline{w}_b^{(m)} \\ -1 \end{bmatrix} \quad (14)$$

Substituindo esse resultado na equação (12) para ordem  $m+1$ :

$$e_f^{(m+1)}(n) = x(n) - \left[ \underline{w}_f^{(m+1)} \right]^T \underline{x}^{(m+1)}(n-1)$$

Então:

$$e_f^{(m+1)}(n) = x(n) - \underbrace{\begin{bmatrix} \underline{w}_f^{(m)} \\ 0 \end{bmatrix}^T \underline{x}^{(m+1)}(n-1)}_{e_f^{(m)}(n)} - k_{m+1} \underbrace{\begin{bmatrix} -\underline{w}_b^{(m)} \\ 1 \end{bmatrix}^T \underline{x}^{(m+1)}(n-1)}_{e_b^{(m)}(n-1)}$$

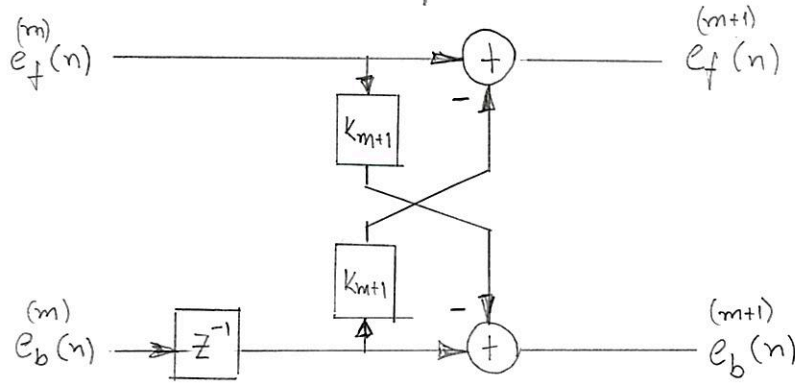
Portanto,

$$e_f^{(m+1)}(n) = e_f^{(m)}(n) - k_{m+1} e_b^{(m)}(n-1)$$

Usando a equação do erro retrógrado, obtemos:

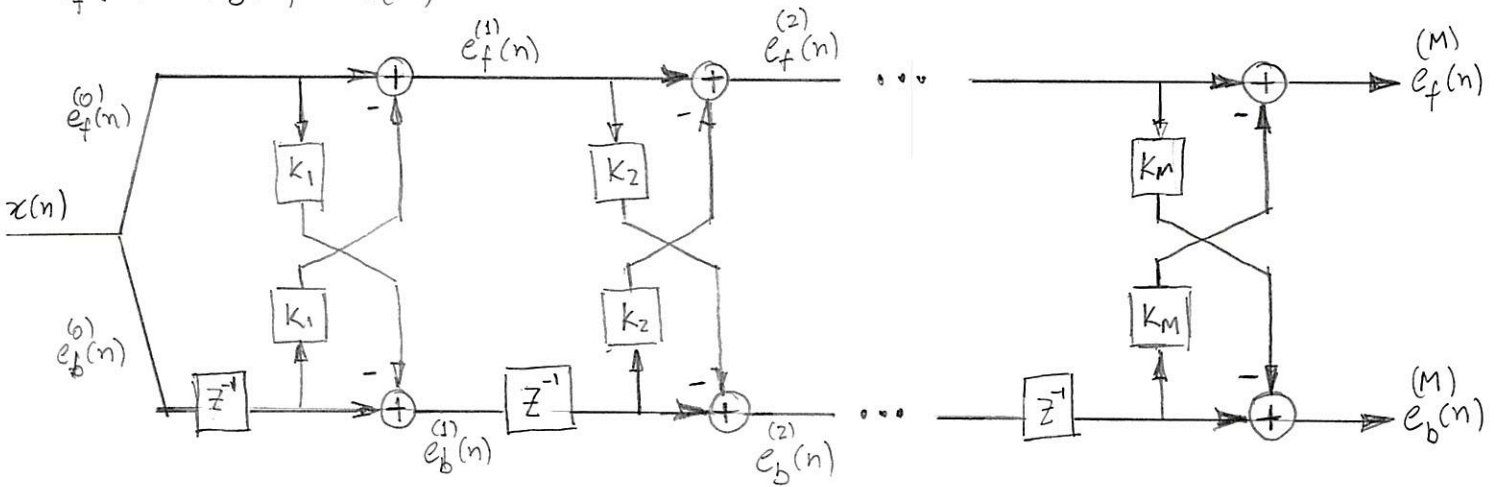
$$e_b^{(m+1)}(n) = e_b^{(m)}(n-1) - k_{m+1} e_f^{(m)}(n)$$

Essas equações podem ser representadas a partir do seguinte diagrama:



Concatenando blocos deste tipo, obtemos uma estrutura em treliça que calcula os erros de predição progressivo e retrógrado de ordem  $M$ :

$$e_f^{(0)}(n) = e_b^{(0)}(n) = x(n)$$



Note que

$$k_m = \frac{1}{P_{m-1}} \left[ r_x(m) - \sum_{i=1}^{m-1} w_{f_i} r_x(m-i) \right] = \frac{\overbrace{\left( x(n) - \sum_{i=1}^{m-1} w_{f_i} x(n-i) \right) x(n-m)}^{e_f^{(m-1)}}}{E \left\{ |e_f^{(m-1)}|^2 \right\}}$$

$$k_m = \frac{E \left\{ e_f^{(m-1)} x(n-m) \right\}}{E \left\{ |e_f^{(m-1)}|^2 \right\}}$$

Os coeficientes  $k_m$  são conhecidos como coeficientes de correlação parcial.



# Predição Progressiva a passo arbitrário

Estimar  $x(n)$  a partir de  $x(n-L), x(n-L-1), \dots, x(n-L-M+1)$  com  $L=1, 2, \dots$  sendo o passo de predição.

$$\hat{x}(n) = w_{f0} x(n-L) + w_{f1} x(n-L-1) + \dots + w_{fM-1} x(n-L-M+1)$$

$$= \sum_{i=0}^{M-1} w_{fi} x(n-L-i) = \begin{bmatrix} w_{f0} \\ \vdots \\ w_{fM-1} \end{bmatrix}^T \cdot \begin{bmatrix} x(n-L) \\ \vdots \\ x(n-L-M+1) \end{bmatrix} = \underline{w}_f^T \underline{x}(n-L)$$

Preditor ótimo:

$$\underline{w}_f = E \left\{ \underline{x}(n-L) \cdot \underline{x}^T(n-L) \right\}^{-1} E \left\{ \underline{x}(n-L) x(n) \right\} = \boxed{R_x^{-1} \underline{r}_x(L)}$$

em que  $\underline{r}_x(L) = \begin{bmatrix} r_x(L) \\ r_x(L+1) \\ \vdots \\ r_x(L+M-1) \end{bmatrix}$

Erro de predição:

$$e_f(n) = x(n) - \hat{x}(n) = x(n) - \underline{w}_f^T \underline{x}(n-L)$$

Considerando o vetor  $\underline{x}(n) = [x(n) \ x(n-1) \ \dots \ x(n-L) \ \dots \ x(n-L-M+1)]^T$ :

$$e_f(n) = \left[ \underbrace{1 \ 0 \ 0 \ \dots \ 0 \ 0}_{L-1 \text{ zeros}} \ -\underline{w}_f^T \right] \underline{x}(n) \Rightarrow e_f(n) = \underline{a}^T \underline{x}(n)$$

$x(n) \rightarrow \begin{array}{c} \text{FEP} \\ \hline A(z) \end{array} \rightarrow e_f(n) \quad A(z) = 1 - w_{f0} z^{-L} - \dots - w_{fM-1} z^{-L-M+1}$

# Predição Retrógrada a passo arbitrário

Estimar  $x(n-L-M+1)$  a partir de  $x(n), x(n-1), \dots, x(n-M+1)$ , com  $L=1, 2, \dots$  sendo o passo de predição

$$\hat{x}(n-L-M+1) = w_{b_0} x(n) + w_{b_1} x(n-1) + \dots + w_{b_{M-1}} x(n-M+1)$$

$$= \sum_{i=0}^{M-1} w_{b_i} x(n-i) = \begin{bmatrix} w_{b_0} \\ w_{b_1} \\ \vdots \\ w_{b_{M-1}} \end{bmatrix}^T \cdot \begin{bmatrix} x(n) \\ x(n-1) \\ \vdots \\ x(n-M+1) \end{bmatrix} = \underline{w}_b^T \underline{x}(n)$$

Preditor ótimo:

$$\underline{w}_b = E \left\{ \underline{x}(n) \underline{x}(n)^T \right\}^{-1} E \left\{ \underline{x}(n) x(n-L-M+1) \right\} = R_x^{-1} \cdot \underbrace{\begin{bmatrix} r_x(L+M-1) \\ r_x(L+M-2) \\ \vdots \\ r_x(L) \end{bmatrix}}_{\underline{r}_x^B(L)} =$$

$$\underline{w}_b = R_x^{-1} \underline{r}_x^B(L)$$


Erro de Predição

$$e_b(n) = x(n-L-M+1) - \hat{x}(n-L-M+1) = x(n-L-M+1) - \underline{w}_b^T \underline{x}(n)$$

Expandindo o vetor  $\underline{x}(n)$  para  $\underline{x}(n) = [x(n) \ x(n-1) \ \dots \ x(n-L-M+1)]^T$ :


$$e_b(n) = \begin{bmatrix} -\underline{w}_b^T & \underbrace{0 \ 0 \ \dots \ 0}_L & 1 \end{bmatrix} \underline{x}(n) = \underline{u}^T \underline{x}(n)$$

$$U(z) = -w_{b_0} - w_{b_1} z^{-1} - \dots - w_{b_{M-1}} z^{-(M-1)} + z^{-(L+M-1)}$$



# Exemplo: Equalização de Canais de Comunicação

$$\eta(n) \sim N(0, \sigma^2)$$



iid  
 $\{-1, +1\}$   
 $p_s(-1) = p_s(+1) = 0,5$

$$H(z) = h_0 + h_1 z^{-1} + h_2 z^{-2} + h_3 z^{-3} + h_4 z^{-4}$$

P/  $N=5$ :

$$\begin{aligned} x(n) &= h_0 s(n) + h_1 s(n-1) + h_2 s(n-2) + h_3 s(n-3) + h_4 s(n-4) + \eta(n) \\ x(n-1) &= h_0 s(n-1) + h_1 s(n-2) + h_2 s(n-3) + h_3 s(n-4) + h_4 s(n-5) + \eta(n-1) \\ x(n-2) &= h_0 s(n-2) + h_1 s(n-3) + h_2 s(n-4) + h_3 s(n-5) + h_4 s(n-6) + \eta(n-2) \\ x(n-3) &= h_0 s(n-3) + h_1 s(n-4) + h_2 s(n-5) + h_3 s(n-6) + h_4 s(n-7) + \eta(n-3) \\ x(n-4) &= h_0 s(n-4) + h_1 s(n-5) + h_2 s(n-6) + h_3 s(n-7) + h_4 s(n-8) + \eta(n-4) \\ x(n-5) &= h_0 s(n-5) + h_1 s(n-6) + h_2 s(n-7) + h_3 s(n-8) + h_4 s(n-9) + \eta(n-5) \end{aligned}$$

FEP Progressivo:

Passo um ( $L=1$ ) e  $M=2$ :  $e_f(n) = x(n) - w_{f0} x(n-1) - w_{f1} x(n-2)$

Idealmente, se o FEP eliminar toda a redundância:  $e_f(n) = h_0 s(n) + \eta'(n)$

Passo 2 ( $L=2$ ) e  $M=2$ :  $e_f(n) = x(n) - w_{f0} x(n-2) - w_{f1} x(n-3)$

Idealmente:  $e_f(n) = h_0 s(n) + h_1 s(n-1) + \eta'(n)$

Passo 3 ( $L=3$ ) e  $M=2$ :  $e_f(n) = x(n) - w_{f0} x(n-3) - w_{f1} x(n-4)$

Idealmente:  $e_f(n) = h_0 s(n) + h_1 s(n-1) + h_2 s(n-2) + \eta'(n)$

Passo 4 ( $L=4$ ) e  $M=2$ :  $e_f(n) = x(n) - w_{f0} x(n-4) - w_{f1} x(n-5)$

Idealmente  $e_f(n) = h_0 s(n) + h_1 s(n-1) + h_2 s(n-2) + h_3 s(n-3) + \eta'(n)$

Generalizando, idealmente o erro de predição programada de passo  $L$  resulta em

$$e_f(n) = h_0 s(n) + h_1 s(n-1) + \dots + h_{L-1} s(n-L+1) + \eta'(n)$$

O FEP atua no sentido de manter a resposta ao impulso do canal, eliminando seus coeficientes finais.

### FEP Retrógrado:

- Passo unitário ( $L=1$ ) e  $M=2$ :  $e_b(n) = x(n-2) - w_{b0} x(n) - w_{b1} x(n-1)$

Idealmente:  $e_b(n) = h_4 s(n-6) + \eta'(n)$

- Passo 2 ( $L=2$ ) e  $M=2$ :  $e_b(n) = x(n-3) - w_{b0} x(n) - w_{b1} x(n-1)$

Idealmente:  $e_b(n) = h_3 s(n-6) + h_4 s(n-7) + \eta'(n)$

- Passo 3 ( $L=3$ ) e  $M=2$ :  $e_b(n) = x(n-4) - w_{b0} x(n) - w_{b1} x(n-1)$

Idealmente:  $e_b(n) = h_2 s(n-6) + h_3 s(n-7) + h_4 s(n-8) + \eta'(n)$


E assim por diante. Generalizando, temos

$$e_b(n) = h_{N-L} s(n-N-M+1) + \dots + h_{N-1} s(n-N-M-L+2) + \eta'(n)$$

Note que o FEP retrógrado atua no sentido de manter a resposta ao impulso do canal, eliminando seus coeficientes iniciais. Quanto maior o passo de predição, menos coeficientes são eliminados.

# Cascata de FEP's

1) FEP Progressivo de passo arbitrário seguido de FEP Retrógrado de passo unitário:



Preditor progressivo com  $M_f$  coeficientes e retrógrado de  $M_b$  coeficientes. Considerando o caso ideal, em que toda a redundância é removida, temos:

$$e_f(n) = h_0 s(n) + h_1 s(n-1) + \dots + h_{L-1} s(n-L+1) + \eta'(n)$$

$$\vdots$$

$$e_f(n-M_b+1) = h_0 s(n-M_b+1) + h_1 s(n-M_b) + \dots + h_{L-1} s(n-M_b-L+2) + \eta'(n-M_b+1)$$

$$e_f(n-M_b) = h_0 s(n-M_b) + h_1 s(n-M_b-1) + \dots + h_{L-1} s(n-M_b-L+1) + \eta'(n-M_b)$$

O erro retrógrado é dado por:


$$e_b(n) = e_f(n-M_b) - \underline{W}_b^T \begin{bmatrix} e_f(n) \\ \vdots \\ e_f(n-M_b+1) \end{bmatrix}$$

Dessa forma, considerando que o FEP retrógrado elimine toda redundância entre  $e_f(n-M_b)$  e as entradas do preditor, temos

$$e_b(n) = h_{L-1} s(n-M_b-L+1) + \eta'(n-M_b)$$

A cascata tende a recuperar o sinal  $s(n)$  multiplicado pelo coeficiente  $(L-1)$  do canal e com um atraso  $(M_b+L-1)$ , ou seja, que depende do passo de predição progressiva e do número de coeficientes do preditor retrógrado.

2) FEP Retrógrado de passo arbitrário seguido de FEP Progressivo de passo unitário.



Preditor retrógrado com  $M_b$  coeficientes e progressivo de  $M_f$  coeficientes. Novamente considerando o caso ideal, o erro retrógrado é dado por:

$$e_b(n) = h_{N-L} s(n-N-M_b+1) + \dots + h_{N-1} s(n-N-M_b-L+2) + \eta'(n)$$

$$e_b(n-1) = h_{N-L} s(n-N-M_b) + \dots + h_{N-1} s(n-N-M_b-L+1) + \eta'(n-1)$$

⋮

$$e_b(n-M_f) = h_{N-L} s(n-N-M_b-M_f+1) + \dots + h_{N-1} s(n-N-M_b-M_f-L+2) + \eta'(n-M_f)$$

O erro de predição progressivo é obtido a partir da diferença entre  $e_b(n)$  e a combinação linear de  $e_b(n-1)$ ,  $e_b(n-2)$ , ...,  $e_b(n-M_f)$ . Assim, considerando que idealmente o FEP progressivo elimina toda a redundância, temos que a saída de cascata é:

$$e_f(n) = h_{N-L} s(n-N-M_b+1) + \eta'(n)$$

Nesse caso, a cascata gera uma estimativa atrasada de  $s(n)$ , com fator de escala  $h_{N-L}$  e atraso  $(N+M_b-1)$ . Note que o atraso não depende do passo de predição do primeiro estágio de cascata, como ocorre na cascata Progressiva-Retrógrada.