

# Lección 2: Análisis de Predicción Lineal


Dr. Jesús Savage  
Dr. Carlos Rivera

6 de septiembre de 2021

# Índice

- 1 Análisis de Predicción Lineal
- 2 Filtro de Predicción y Error
- 3 Filtro de Wiener
- 4 Vector Gradiente
- 5 Filtros Adaptables

# Análisis de Predicción Lineal



Sea la serie de tiempo  $u(n), u(n-1), \dots, u(n-M)$ .

Sea  $U(n|\underline{u}_{n-1})$  el valor de predicción  $u(n)$  dado este conjunto de muestras  $\underline{u}_{n-1}^T = [u_{n-1}, u_{n-2}, \dots, u_{n-M}]$ .

El valor de predicción se obtiene a través de una función con este vector:

$$U(n|\underline{u}_{n-1}) = f(u(n-1), \dots, u(n-M))$$

# Análisis de Predicción Lineal

Predicción lineal cuando la función es simplemente una combinación lineal de las muestras  $u(n-1), u(n-2), \dots, u(n-M)$

$$U(n|\underline{u}_{n-1}) = \sum_{k=1}^M w_k^* u(n-k)$$

Las  $w_k$  son constantes complejas y  $*$  es el conjugado de estos valores.

Los valores de  $u(n-1), u(n-2), \dots, u(n-M)$  se utilizan para hacer la predicción de la muestra  $u(n)$ . Este tipo de predicción se denomina predicción hacia adelante. También se podría utilizar  $u(n), u(n-1), \dots, u(n-M+1)$  para hacer la predicción de la muestra  $u(n-M)$ . Este tipo de proyección se llama predicción hacia atrás

# Análisis de Predicción Lineal





Figura: Representación gráfica del predictor de la muestra  $u(n)$  con la función  $U(n|\underline{u}_{n-1})$ .

# Filtro de Predicción y Error

Error de predicción.

$$f_M(n) = u(n) - U(n|\underline{u}_{n-1})$$

Donde la  $M$  es el número de coeficientes del filtro de predicción.



En la teoría Wiener, el criterio del error cuadrático medio mínimo es utilizado para optimizar el filtro, es decir encontrar los pesos óptimos

$$\mathbf{w}^T = [w_1, w_2, \dots, w_M]$$

$$J(\underline{w}) = E[\underbrace{f_m(n)f_m^*(n)}]$$

Recordar:

$$x = A + Bj$$

$$|x| = \sqrt{A^2 + B^2}$$

$$x^* = A - Bj$$

$$x \cdot x^* = (A + Bj)(A - Bj) = A^2 + B^2 = |x|^2$$

Magnitud de un número complejo al cuadrado

# Filtro de Predicción y Error

Por lo tanto  $J(\underline{w})$ , el error cuadrático medio, es un escalar real y positivo. Minimizando  $J(\underline{w})$  obtenemos un filtro ideal óptimo en el sentido de error cuadrático medio mínimo.

Usando notación matricial.

$$\underline{w}^T = [w_1, w_2, \dots, w_M]$$

El vector de entradas se define como:

$$\underline{u}^T(n-1) = [u_{n-1}, u_{n-2}, \dots, u_{n-M}].$$



# Filtro de Predicción y Error

Entonces el estimado :

$$U(n|\underline{u}_{n-1}) = \underline{w}^H \cdot \underline{u}(n-1) = [w_1^*, w_2^*, \dots, w_M^*] \cdot \begin{bmatrix} u(n-1) \\ u(n-2) \\ \vdots \\ u(n-M) \end{bmatrix} =$$
$$= \sum_{k=1}^M w_k^* \cdot u(n-k)$$

Donde H significa transposición Hermitiana (que es el transpuesta de un vector y haciendo su conjugado)

# Filtro de Predicción y Error

Tomando el conjugado en ambos lados de la expresión:

$$U^*(n|\underline{u}_{n-1}) = (\underline{w}^H \cdot \underline{u}(n-1))^*$$

Se puede demostrar que:

$$\underbrace{U^*(n|\underline{u}_{n-1})}_{\text{escalar}} = \underline{u}^H(n-1) \cdot \underline{w}$$

Entonces el error de estimación:

$$f_M(n) = u(n) - \underline{w}^H \cdot \underline{u}(n-1)$$

Su conjugado es:

$$f_M^*(n) = u^*(n) - \underline{u}^H(n-1) \cdot \underline{w}$$

# Filtro de Predicción y Error

Por lo tanto error cuadrático medio

$$J(\underline{w}) = E\{f_M(n)f_M^*(n)\} =$$

$$E\{(u(n) - \underline{w}^H \underline{u}(n-1))(u^*(n) - \underline{u}^H(n-1)\underline{w})\}$$

$$= E\{u(n)u^*(n) - \underline{w}^H \underline{u}(n-1)u^*(n) - u(n)\underline{u}^H(n-1)\underline{w} + \underline{w}^H \underline{u}(n-1)\underline{u}^H(n-1)\underline{w}\}$$

$$= E\{u(n)u^*(n)\} - \underline{w}^H E\{\underline{u}(n-1)u^*(n)\} - E\{u(n)\underline{u}^H(n-1)\}\underline{w} + \underline{w}^H E\{\underline{u}(n-1)\underline{u}^H(n-1)\}\underline{w}$$

# Error Cuadrático Medio

1.-  $E \{ u(n)u^*(n) \}$  es igual a la variancia de la entrada  $u(n)$ , asumiendo que  $u(n)$  tiene media igual a cero:

$$\sigma_u^2 = E \{ u(n)u^*(n) \}$$

2.-  $E \{ \underline{u}(n-1)u^*(n) \}$

$$= E \left\{ \begin{bmatrix} u(n-1) \\ u(n-2) \\ \vdots \\ u(n-M) \end{bmatrix} u^*(n) \right\} = E \left\{ \begin{bmatrix} u(n-1)u^*(n) \\ u(n-2)u^*(n) \\ \vdots \\ u(n-M)u^*(n) \end{bmatrix} \right\}$$

$$= \begin{bmatrix} E \{ u(n-1)u^*(n) \} \\ E \{ u(n-2)u^*(n) \} \\ \vdots \\ E \{ u(n-M)u^*(n) \} \end{bmatrix}$$

Definiendo:

$$E\{u(n-k)u^*(n-j)\} = \frac{1}{N} \sum_{n=0}^{N-1} u(n-k)u^*(n-j) = r(j-k)$$

Por lo tanto  $E\{\underline{u}(n-1)u^*\} =$

$$\begin{bmatrix} r(-1) \\ r(-2) \\ r(-3) \\ \vdots \\ r(-M) \end{bmatrix} = \underline{r}$$

$$\begin{aligned}
 3.-E\{u(n)\underline{u}^H(n-1)\} &= E\{[u(n)(u^*(n-1) u^*(n-2) \cdots u^*(n-M))]\} \\
 &= [E\{u(n)u^*(n-1)\} E\{u(n)u^*(n-2)\} \cdots E\{u(n)(u^*(n-M))\}] \\
 &= [r^*(1) r^*(2) \dots r^*(m)] = \underline{r}^H
 \end{aligned}$$

Esto es debido a que  $r^*(i-k) = r[k-i]$

$$4.-E[\underline{u}[n-1]\underline{u}^*(n-1)] =$$

$$E \left[ \begin{bmatrix} u(n-1) \\ u(n-2) \\ \vdots \\ u(n-M) \end{bmatrix} \begin{bmatrix} u^*(n-1) & u^*(n-2) & \dots & u^*(n-M) \end{bmatrix} \right] =$$

$$E \begin{bmatrix} u(n-1)u^*(n-1) & u(n-1)u^*(n-2) & \dots & u(n-1)u^*(n-M) \\ u(n-2)u^*(n-1) & u(n-2)u^*(n-2) & \dots & u(n-2)u^*(n-M) \\ \vdots & \vdots & \ddots & \vdots \\ u(n-M)u^*(n-1) & u(n-M)u^*(n-2) & \dots & u(n-M)u^*(n-M) \end{bmatrix}$$

$$\begin{bmatrix} E\{u(n-1)u^*(n-1)\} & E\{u(n-1)u^*(n-2)\} & \dots & E\{u(n-1)u^*(n-M)\} \\ E\{u(n-2)u^*(n-1)\} & E\{u(n-2)u^*(n-2)\} & \dots & E\{u(n-2)u^*(n-M)\} \\ \vdots & \vdots & \ddots & \vdots \\ E\{u(n-M)u^*(n-1)\} & E\{u(n-M)u^*(n-2)\} & \dots & E\{u(n-M)u^*(n-M)\} \end{bmatrix}$$

$$R = \begin{bmatrix} r(0) & r(1) & \dots & r(M-1) \\ r(-1) & r(0) & \dots & r(M-2) \\ \vdots & \vdots & \ddots & \vdots \\ r(-M+1) & r(-M+2) & \dots & r(0) \end{bmatrix}$$

Para procesos estacionarios la matriz de correlación  $R$  es definida únicamente especificando la sucesión de autocorrelación de los valores de entrada:  $r[0], r[1], \dots, r[M-1]$

Entonces el error cuadrático medio

$$J(\underline{w}) = E[\underbrace{f_m(n)f_m^*(n)}] = \sigma_u^2 - \underline{w}^H \underline{r} - \underline{r}^H \underline{w} + \underline{w}^H R \underline{w}$$

El objetivo es encontrar los pesos  $\underline{w}$  que minimizen este error.

Cada uno de los pesos es un número complejo:  $w_k = w_{kR} + jw_{kim}$

$$\frac{dJ(\underline{w})}{d\underline{w}} \stackrel{?}{=} 0$$

Para el primer término  $\sigma_u^2$  la derivada con respecto a  $\underline{w}$  es cero.



Para el segundo termino:

$$\underline{g} = \underline{w}^H \cdot \underline{r} = \sum_{k=1}^M w_k^* \cdot r_k = \sum_{k=1}^M (w_{kR} - jw_{kim})r_k$$

$$\frac{\partial \underline{g}}{\partial w_{kR}} = r_k \quad ; \quad \frac{\partial \underline{g}}{\partial w_{kim}} = -jr_k$$

$$\Rightarrow \frac{\partial \underline{g}}{\partial \underline{w}} = \begin{bmatrix} \frac{\partial \underline{g}}{\partial w_{1R}} + j \frac{\partial \underline{g}}{\partial w_{1im}} \\ \frac{\partial \underline{g}}{\partial w_{2R}} + j \frac{\partial \underline{g}}{\partial w_{2im}} \\ \vdots \\ \frac{\partial \underline{g}}{\partial w_{MR}} + j \frac{\partial \underline{g}}{\partial w_{Mim}} \end{bmatrix}$$

$$= \begin{bmatrix} r_1 + j \cdot (-jr_1) \\ r_2 + j \cdot (-jr_2) \\ \vdots \\ r_M + j \cdot (-jr_M) \end{bmatrix} = \begin{bmatrix} 2r_1 \\ 2r_2 \\ \vdots \\ 2r_m \end{bmatrix} = 2\underline{r} = \frac{d(\underline{w}^H \cdot \underline{r})}{d\underline{w}}$$

Para el tercer termino:

$$\underline{g} = \underline{r}^H \underline{w} = \sum_{k=1}^M r_k^* (w_{kR} + jw_{kim})$$

$$\frac{\partial \underline{g}}{\partial w_{kR}} = r_k^* \quad ; \quad \frac{\partial \underline{g}}{\partial w_{kim}} = jr_k^*$$

$$\frac{\partial \underline{g}}{\partial \underline{w}} = \begin{bmatrix} r_1^* + j \cdot (jr_1^*) \\ r_2^* + j \cdot (jr_2^*) \\ \vdots \\ r_M^* + j \cdot (jr_M^*) \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix} = \underline{0}$$

$$\Rightarrow \frac{d(\underline{r}^H \underline{w})}{d\underline{w}} = \underline{0}$$

Para el cuarto termino:

$$g = \underline{w}^H R \underline{w}$$

Recordar que:  $\frac{d}{dx}(uv) = u \cdot \frac{dv}{dx} + v \frac{du}{dx}$

Haciendo:

$$\underline{c}_1^H = \underline{w}^H R \quad \Rightarrow \quad g = \underline{c}_1^H \underline{w} \quad \Rightarrow \quad \begin{aligned} u &= \underline{w}^H R \\ v &= \underline{w} \end{aligned}$$

Entonces

$$\frac{dg}{d\underline{w}} = \frac{d(\underline{c}_1^H \underline{w})}{d\underline{w}} = \underline{0}$$

Ahora con:  $\underline{c}_2 = R \underline{w} \quad \Rightarrow \quad g = \underline{w}^H \underline{c}_2$

$$\begin{aligned} u &= R \underline{w} \\ v &= \underline{w}^H \end{aligned}$$

$$\frac{dg}{d\underline{w}} = \frac{d(\underline{w}^H \underline{c}_2)}{d\underline{w}} = 2 \cdot \underline{c}_2 = 2 \cdot R \underline{w}$$

$$\frac{d\underline{r}^H}{d\underline{w}} = \underline{0} + 2R \underline{w}$$

# Vector Gradiente

Finalmente, el gradiente de  $J(\underline{w})$  con respecto  $\underline{w}$ :

$$\nabla J(\underline{w}) = \frac{dJ(\underline{w})}{d\underline{w}} = \underline{0} - 2\underline{r} + \underline{0} + 2R\underline{w}$$

Por lo tanto para obtener el vector óptimo  $\underline{w}$ , es decir el mínimo de  $J(\underline{w})$

$$\frac{dJ(\underline{w})}{d\underline{w}} = \underline{0} = -2\underline{r} + 2R\underline{w}$$

$$\underline{r} = R\underline{w} \quad \Rightarrow \quad \boxed{\underline{w}_o = R^{-1}\underline{r}} \quad \text{Solucion de Wiener}$$

# Vector Gradiente

Entonces con el vector óptimo  $\underline{w}_o$ , el error cuadrático medio mínimo es:

$$J_{min}(\underline{w}_o) = \sigma_u^2 - \underline{r}^H \underline{w}_o - \underline{w}_o^H \underline{r} + \underline{w}_o^H R \underline{w}_o$$

ya que  $R \underline{w}_o = \underline{r}$

$$\begin{aligned} &= \sigma_u^2 - \underline{r}^H \underline{w}_o - \underline{w}_o^H \underline{r} + \underline{w}_o^H \underline{r} \\ &= \sigma_u^2 - \underline{r}^H \underline{w}_o = r(0) - \underline{r}^H \underline{w}_o \\ &= E\{|f_M(n)|^2\} \end{aligned}$$

Porque  $R$  es una matriz Toeplitz siempre tiene inversa.

Demostración:

$$R = E\{\underline{u}(n-1)\underline{u}^H(n-1)\}$$

Multiplicando por  $\underline{x}^H$  y por  $\underline{x}$  los dos lados de la ecuación:

$$\begin{aligned}\underline{x}^H R \underline{x} &= \underline{x}^H E\{\underline{u}(n-1)\underline{u}^H(n-1)\} \underline{x} \\ &= E\left\{\left(\underline{x}^H \underline{u}(n-1)\right) \left(\underline{u}^H(n-1) \underline{x}\right)\right\} \\ &= E\left\{\left(\underline{x}^H \underline{u}(n-1)\right) \left(\underline{x}^H \underline{u}(n-1)\right)^*\right\} \\ &= E\left\{\left(\underline{x}^H \underline{u}(n-1)\right) \left(\underline{x}^H \underline{u}(n-1)\right)^*\right\} \\ &= E\left\{\left|\underline{x}^H \underline{u}(n-1)\right|^2\right\} > 0\end{aligned}$$

$$= E \left\{ \left| x^H \underline{u}(n-1) \right|^2 \right\} > 0$$

R se dice que es definida semipositiva si su forma cuadrática asociada nunca es negativa para cualquier vector  $\underline{x}$ . Para una matriz semipositiva su determinante no es cero y tiene inversa.

$$\underbrace{\underline{x}^H \cdot R \underline{x}} \geq 0$$

$$R^{-1} = \frac{|adjunta \text{ de } R|}{|R|}$$

Ser definida positiva implica que su determinante y todos sus menores principales son más grandes que cero  $\begin{vmatrix} r(0) & r(1) \\ r^*(1) & r(0) \end{vmatrix} > 0$

Implica que la matriz es no singular y por lo tanto tiene inversa.



# Filtro de Wiener

Ejemplo:

Se tiene la función  $x_n = n$  y se desea encontrar una función de predicción de ésta utilizando su valores anteriores:

$$\hat{x}_n = X(n|\underline{x}_{n-1}) = f(x_{n-1}, x_{n-2}, \dots, x_{n-m}) = w_1 \cdot x_{n-1} + w_2 \cdot x_{n-2}$$

Utlizando la solución de Wiener para encontrar los coeficiente óptimos:

$$R \cdot \underline{w} = \underline{r} \rightarrow \underline{w} = R^{-1} \underline{r}$$

# Filtro de Wiener

Donde:

$$R = \begin{bmatrix} r(0) & r(1) \\ r(-1) & r(0) \end{bmatrix} \quad y \quad \underline{r} = [r(-1) \quad r(-2)]$$

$$r(\zeta) = \frac{1}{N} \sum_{i=0}^{N-1} x_i x_{i+\zeta} = \frac{1}{N} \sum_{i=0}^{N-1} i \cdot (i + \zeta)$$

$$= \frac{1}{N} \sum_{i=0}^{N-1} i^2 + \frac{1}{N} \sum_{i=0}^{N-1} i \cdot \zeta$$

Recordar que:

$$\sum_{i=1}^N i = \frac{N(N-1)}{2}; \quad \sum_{i=1}^N i^2 = \frac{N(N-1)(2N-1)}{6}$$

# Filtro de Wiener

Por lo tanto:

$$\begin{aligned}r(\zeta) &= \frac{1}{N} \frac{N(N-1)(2N-1)}{6} + \frac{\zeta}{N} \frac{N \cdot (N-1)}{2} \\ &= \frac{(N-1)(2N-1)}{6} + \frac{\zeta}{2} \cdot (N-1)\end{aligned}$$

Entonces

$$\begin{aligned}r(0) &= \frac{(N-1)(2N-1)}{6} \\ r(1) &= \frac{(N-1)(2N-1)}{6} + \frac{1}{2}(N-1) \\ r(-1) &= \frac{(N-1)(2N-1)}{6} - \frac{1}{2}(N-1)\end{aligned}$$

## Filtro de Wiener

$$r(-2) = \frac{(N-1)(2N-1)}{6} - (N-1)$$

Usando 10 muestras, es decir  $N = 10$ :

$$r(0) = \frac{(10-1)(20-1)}{6} = \frac{9 \times 19}{6} = 28.5$$

$$r(1) = 28.5 + \frac{9}{2} = 33.0$$

$$r(-1) = 28.5 - \frac{9}{2} = 24$$

$$r(-2) = 28.5 - 9 = 19.5$$

# Filtro de Wiener

Resolviendo el sistema de ecuaciones para encontrar el vector de pesos óptimo  $\underline{w}_0$ :

$$R\underline{w}_0 = \underline{r}$$

$$\begin{bmatrix} r(0) & r(1) \\ r(-1) & r(0) \end{bmatrix} \begin{bmatrix} w_1 \\ w_2 \end{bmatrix} = \begin{bmatrix} r(-1) \\ r(-2) \end{bmatrix}$$

$$\begin{bmatrix} 28.5 & 33.0 \\ 24 & 28.5 \end{bmatrix} \begin{bmatrix} w_1 \\ w_2 \end{bmatrix} = \begin{bmatrix} 24 \\ 19.5 \end{bmatrix}$$

$$\det(R) = r(0)^2 - r(-1)r(1) = (28.5)^2 - 24 \cdot 33.0 = 20.25 \quad (1)$$

## Filtro de Wiener

$$\begin{aligned}w_1 &= \frac{\left| \begin{bmatrix} r(-1) & r(1) \\ r(-2) & r(0) \end{bmatrix} \right|}{\det} = \frac{(r(-1) \cdot r(0) - r(-2) \cdot r(1))}{\det} \\ &= \frac{24 \cdot 0 \cdot 28.5 - 19.5 \cdot 5 \cdot 33}{20.25} = \frac{40.5}{20.25} = 2\end{aligned}$$

$$\begin{aligned}w_2 &= \frac{\left| \begin{bmatrix} r(0) & r(-1) \\ r(-1) & r(-2) \end{bmatrix} \right|}{\det} = \frac{(r(0) \cdot r(-2) - r(-1) \cdot r(1))}{\det} \\ &= \frac{28.5 \cdot 19.5 - 24 \cdot 24}{20.25} = \frac{-20.25}{20.25} = -1\end{aligned}$$

# Filtro de Wiener

Entonces el vector óptimo de pesos  $\underline{w}_o$  es:

$$\underline{w}_o = [2 \quad -1]$$

Por lo tanto el predictor es:

$$\hat{x}_n = 2x_{n-1} - 1x_{n-2}$$

Con  $x_n = n$

Para  $x_3 = 3$  su predictor es:

$$\hat{x}_3 = 2x_2 - 1x_1 = 2 \cdot 2 - 1 = 3$$

# Filtro de Wiener

Para  $x_{10} = 10$  su predictor es:

$$\hat{x}_{10} = 2 \cdot 9 - 8 = 10$$

Para  $x_n = n$  su predictor es:

$$\begin{aligned}\hat{x}_n &= 2x_{n-1} - x_{n-2} = 2(n-1) - (n-2) \\ &= 2n - 2 - n + 2 = n\end{aligned}$$



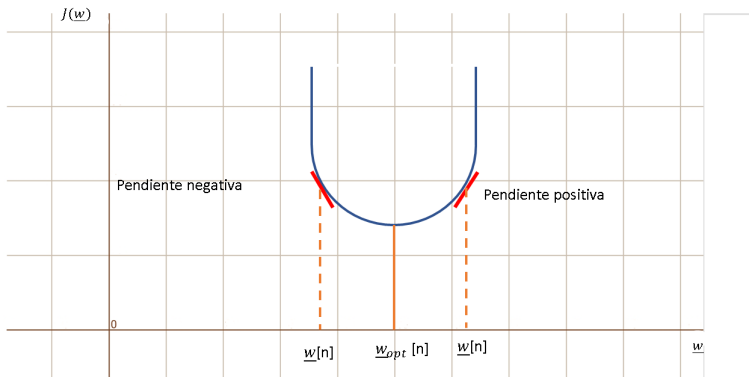
# Filtros Adaptables

A medida que el número de coeficientes del predictor se incrementa entonces la matriz de correlaciones se hace más grande y para obtener su inversa se vuelve un problema complicado, por lo tanto se requiere otra forma para encontrar los pesos  $\underline{w}$  en forma iterativa.

Calcular la matriz inversa de correlaciones  $R$  es un proceso engorroso, entonces se pueden usar otros métodos como el algoritmo de Levinson-Durbin, filtros adaptables, entre otros.

# Filtros Adaptables

Bernard Widrow propuso el método de los filtros adaptables.



# Filtros Adaptables

$$\underline{w}[n+1] = \underline{w}[n] + \frac{1}{2}\mu[-\nabla(n)]$$

$$\nabla(n) = \frac{dJ(n)}{d\underline{w}(n)} = -2\underline{r} + 2R\underline{w}[n]$$

$$\underline{w}[n+1] = \underline{w}[n] + \mu[\underline{r} - R\underline{w}[n]]$$

$$\underline{r} = E\{\underline{u}(n-1)u^*(n)\} = \begin{bmatrix} E\{u(n-1)u^*(n)\} \\ E\{u(n-2)u^*(n)\} \\ \vdots \\ E\{u(n-M)u^*(n)\} \end{bmatrix}$$

$$R = E\{\underline{u}(n-1)\underline{u}^*(n-1)\}$$

# Filtros Adaptables

Usando estimadores

$$\hat{r}(n) = \underline{u}(n-1)u^*(n)$$

$$\hat{R} = \underline{u}(n-1)\underline{u}^*(n-1)$$

Entonces el estimado de

$$\underline{w}[n+1] = \underline{w}[n] + \mu[\underline{r} - R\underline{w}[n]]$$

es:

$$\hat{\underline{w}}[n+1] = \hat{\underline{w}}[n] + \mu[\hat{r} - \hat{R}\hat{\underline{w}}[n]]$$

$$\hat{\underline{w}}[n+1] = \hat{\underline{w}}[n] + \mu[\underline{u}(n-1)u^*(n) - \underline{u}(n-1)\underline{u}^*(n-1) \cdot \hat{\underline{w}}[n]]$$

# Filtros Adaptables

$$= \hat{\underline{w}}[n] + \mu \underline{u}(n-1) [u^*(n) - \underline{u}^*(n-1) \cdot \hat{\underline{w}}[n]]$$

Haciendo

$$E^*(n) = u^*(n) - \underline{u}^*(n-1) \cdot \hat{\underline{w}}[n]$$

$$E(n) = u(n) - \hat{\underline{w}}^H[n] \cdot \underline{u}(n-1) \quad \leftarrow \quad \text{error de prediccion}$$

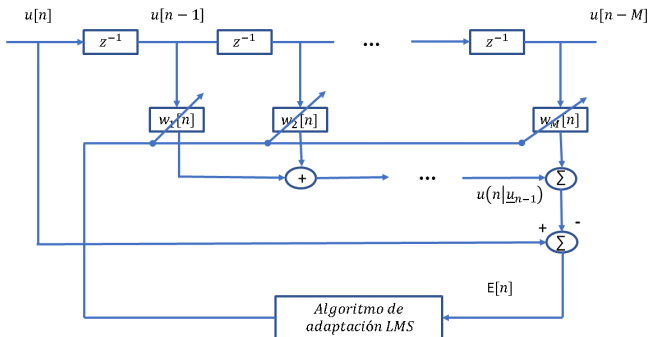
Si los valores de  $\underline{u}$  y  $\hat{\underline{w}}$  son reales, entonces el error de predicción:

$$E(n) = u(n) - \hat{\underline{w}}[n] \cdot \underline{u}(n-1)$$

# Filtros Adaptables


Por lo tanto la formula iterativa para encontrar los pesos  $\underline{w}$  es:

$$\hat{\underline{w}}[n+1] = \hat{\underline{w}}[n] + \mu \underline{u}[n-1] \cdot E(n)$$



# Tracto Vocal

Para la generación de señales de voz se tiene el modelo del tracto vocal:



# Tracto Vocal

El modelo del tracto vocal se definió anteriormente como:

$$H(z) = \frac{\sigma}{\sum_{i=0}^M a_i \cdot z^{-i}}$$

La relación que existe entre los pesos  $\underline{w}$  encontrados por el filtro de Wiener, filtros adaptables LMS, u otros métodos como el algoritmo de Levinson y Durbin, algoritmos genéticos, etc, y los coeficientes del modelo  $\underline{a}$  es la siguiente:

Sea  $\underline{w}^T = [w_1 \quad w_2 \quad \dots \quad w_p]$ , entonces  $\underline{a}^T = [1 - \underline{w}^T]$

$$\underline{a}^T = [a_0 \quad a_1 \quad \dots \quad a_p] = [1 \quad -w_1 \quad -w_2 \quad \dots \quad -w_p]$$



# Tracto Vocal

$$S(z) = \frac{\sigma \cdot E(z)}{\sum_{i=0}^M a_i \cdot z^{-i}}$$

$$S(z) \sum_{i=0}^M a_i \cdot z^i = S(z)a_0 + S(z)a_1z^{-1} + \dots + S(z)a_mz^{-m} = \sigma \cdot E(z)$$


Con  $a_0 = 1$

$$S(z) = \sigma \cdot E(z) - S(z)a_1z^{-1} - \dots - S(z)a_mz^{-m}$$

Obteniendo la transformada Z inversa de  $S(z)$ :

$$Z^{-1}\{S(z)\} = s[n] = \sigma e[n] - a_1 s[n-1] - a_2 s[n-2] \cdots - a_m s[n-m]$$


Dada una señal de voz los componentes del modelo para cada bloque de la señal  $j$  que representan ésta son:  $\underline{a}^j, \sigma_j, e^j[n]$



Los vectores  $\underline{a}^j$  pueden ser encontrados directamente de la señal de voz usando los métodos que se indicaron anteriormente.

# Filtros Adaptables

Los filtros adaptables se pueden usar para encontrar la función de transferencia de sistema lineal e invariante en el tiempo desconocidos.



$$Y(z) = X(z) \cdot H(z)$$

Si

$$H(z) = \frac{B(z)}{1 + A(z)} = \frac{b_0 + b_1 z^{-1} + \dots + b_L z^{-L}}{1 + a_1 z^{-1} + \dots + a_M z^{-M}}$$

$$Y(z) = \frac{X(z)(b_0 + b_1 z^{-1} + \dots + b_L z^{-L})}{1 + a_1 z^{-1} + \dots + a_M z^{-M}}$$

# Filtros Adaptables


En el tiempo

$$y[n] = b_0x[n] + b_1x[n-1] + \dots + b_lx[n-l] \\ - a_1y[n-1] - a_2y[n-2] - \dots - a_my[n-M]$$

Entonces se utilizan los filtros adaptables para encontrar los estimados de los coeficientes  $b_i$ s y  $a_i$ s.

$$\hat{y}[n] = \hat{b}_0x[n] + \hat{b}_1x[n-1] + \dots + \hat{b}_lx[n-l] \\ - \hat{a}_1\hat{y}[n-1] - \hat{a}_2\hat{y}[n-2] - \dots - \hat{a}_m\hat{y}[n-M]$$

# Filtros Adaptables

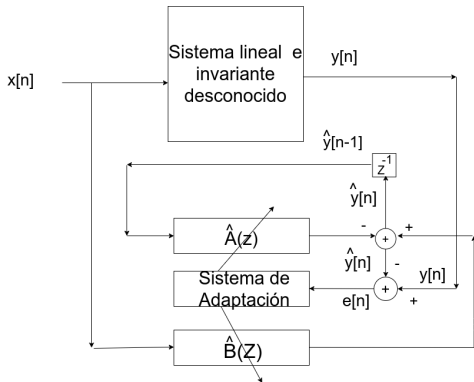


$$e[n] = y[n] - \hat{y}[n] = y[n] - \hat{b}_0 x[n] - \hat{b}_1 x[n-1] - \dots - \hat{b}_l x[n-l] \\ + \hat{a}_1 \hat{y}[n-1] + \hat{a}_2 \hat{y}[n-2] + \dots + \hat{a}_m \hat{y}[n-M]$$

# Filtros Adaptables

$$\hat{y}[n] = \hat{b}_0 x[n] + \hat{b}_1 x[n-1] + \dots + \hat{b}_l x[n-l] \\ - \hat{a}_1 \hat{y}[n-1] - \hat{a}_2 \hat{y}[n-2] - \dots - \hat{a}_m \hat{y}[n-M]$$

$$e[n] = y[n] - \hat{y}[n]$$



# Bibliografía

- \* Libro: Adaptive Filter Theory, Simon S. Haykin
- \* Libro: Adaptive Signal Processing, Bernard Widrow