


3.TEORIA FILTRĂRII LINIARE OPTIMALE

3.1 CRITERIUL DE OPTIMIZARE



Se cunoaște semnalul staționar în sens larg, de medie nulă


$$x(n) = d(n) + v(n),$$

Semnal util

Perturbație

Dorim un filtru $H(z)$ care să extragă semnalul util.

3.1 CRITERIUL DE OPTIMIZARE




$$h(n) = w_n^*, \quad n = 0, 1, \dots, N-1$$

$$y(n) = (h * x)(n) = \sum_{k=0}^{N-1} w_k^* x(n-k), \quad n = 0, 1, \dots$$

și

$$e(n) = d(n) - \sum_{k=0}^{N-1} w_k^* x(n-k)$$

3.1 CRITERIUL DE OPTIMIZARE



Cu notățiile

$$\mathbf{x}(n) = [x(n), \dots, x(n - N + 1)]^T;$$

$$\mathbf{w} = [w_0, w_1, \dots, w_{N-1}]^T;$$

$$e(n) = d(n) - \mathbf{w}^H \mathbf{x}(n)$$

3.1 CRITERIUL DE OPTIMIZARE

Funcție cost: *eroarea medie patratică*

$$J = E\{|e(n)|^2\} = E\{e(n)e^*(n)\}$$

$$\begin{aligned} J &= E\{[d(n) - \mathbf{w}^H \mathbf{x}(n)][d^*(n) - \mathbf{x}^H(n)\mathbf{w}]\} \\ J &= E\{d(n)d^*(n)\} + \mathbf{w}^H E\{\mathbf{x}(n)\mathbf{x}^H(n)\}\mathbf{w} - \mathbf{w}^H E\{\mathbf{x}(n)d^*(n)\} - \\ &\quad - E\{d(n)\mathbf{x}^H(n)\}\mathbf{w} \end{aligned}$$

$$E\{d(n)d^*(n)\} = \sigma_d^2 \quad (\text{puterea semnalului dorit})$$

$$E\{\mathbf{x}(n)\mathbf{x}^H(n)\} = \mathbf{R} \quad (\text{matricea de autocorelație})$$

$$E\{\mathbf{x}(n)d^*(n)\} = \mathbf{p} \quad (\text{vectorul corelației între semnalul de intrare și semnalul dorit})$$

$$\mathbf{p} = [r_{xd}(0), r_{xd}(-1), \dots, r_{xd}(-N+1)]^T;$$

3.1 CRITERIUL DE OPTIMIZARE

$$J = E\{d(n)d^*(n)\} + \mathbf{w}^H E\{\mathbf{x}(n)\mathbf{x}^H(n)\}\mathbf{w} - \mathbf{w}^H E\{\mathbf{x}(n)d^*(n)\} - E\{d(n)\mathbf{x}^H(n)\}\mathbf{w}$$

$$J = \sigma_d^2 - \mathbf{w}^H \mathbf{p} - \mathbf{p}^H \mathbf{w} + \mathbf{w}^H \mathbf{R} \mathbf{w}$$

3.2 ECUAȚIILE WIENER-HOPF

J - funcție de gradul doi de variabilele complexe

$$w_k = a_k + j b_k, \quad k=0, \dots, N-1.$$

$$J_{\min} \Rightarrow \nabla_{w^*} J = \mathbf{0}$$

∇J - gradientul complex,

$$\nabla_w J = \left[\frac{\partial J}{\partial w_0}, \frac{\partial J}{\partial w_1}, \dots, \frac{\partial J}{\partial w_{N-1}} \right]^T = \mathbf{0}$$

$$\frac{\partial J}{\partial w_i} = \frac{1}{2} \left(\frac{\partial J}{\partial a_i} - j \frac{\partial J}{\partial b_i} \right); \quad \frac{\partial J}{\partial w_i^*} = \frac{1}{2} \left(\frac{\partial J}{\partial a_i} + j \frac{\partial J}{\partial b_i} \right)$$

Minimizarea unei funcții reale de un vector complex

Fie o funcție $f(\mathbf{z}, \mathbf{z}^*) : \mathbb{C}^{2N} \rightarrow \mathbb{R}$. Condiția necesară pentru ca funcția să aibă un minim în \mathbf{z} este ca gradientul complex să se anuleze $\nabla_{\mathbf{z}^*}\{f(\mathbf{z}, \mathbf{z}^*)\} = \mathbf{0}$.

Prin definiție

$$\nabla_{\mathbf{z}} f = \left[\frac{\partial f}{\partial z_0}, \frac{\partial f}{\partial z_1}, \dots, \frac{\partial f}{\partial z_{N-1}} \right]^T$$

$$\nabla_{\mathbf{z}^*} f = \left[\frac{\partial f}{\partial z_0^*}, \frac{\partial f}{\partial z_1^*}, \dots, \frac{\partial f}{\partial z_{N-1}^*} \right]^T$$

$$\frac{\partial f}{\partial z_i} = \frac{1}{2} \left(\frac{\partial f}{\partial a_i} - j \frac{\partial f}{\partial b_i} \right), \quad \frac{\partial f}{\partial z_i^*} = \frac{1}{2} \left(\frac{\partial f}{\partial a_i} + j \frac{\partial f}{\partial b_i} \right), \quad z_i = a_i + j b_i$$

Exemple

$$\frac{\partial z_i}{\partial z_i} = \frac{1}{2} \left(\frac{\partial}{\partial a_i} - j \frac{\partial}{\partial b_i} \right) (a_i + j b_i) = 1$$

$$\frac{\partial z_i}{\partial z_i^*} = \frac{1}{2} \left(\frac{\partial}{\partial a_i} + j \frac{\partial}{\partial b_i} \right) (a_i + j b_i) = 0$$

$$\frac{\partial z_i^*}{\partial z_i} = \frac{1}{2} \left(\frac{\partial}{\partial a_i} - j \frac{\partial}{\partial b_i} \right) (a_i - j b_i) = 0$$

$$\nabla_{\mathbf{z}} \mathbf{z}^* = \mathbf{0}; \quad \nabla_{\mathbf{z}^*} \mathbf{z} = \mathbf{0}$$

Observație – \mathbf{z} și \mathbf{z}^* sunt tratate ca două variabile distincte.

Gradientul în raport \mathbf{z} al unei cantități ce nu depinde de \mathbf{z} este nul.

$$\nabla_{\mathbf{z}} \{\mathbf{p}^H \mathbf{z}\} = \mathbf{p}^*$$

$$\nabla_{\mathbf{z}^*} \{\mathbf{p}^H \mathbf{z}\} = \mathbf{0}$$

$$\frac{\partial}{\partial z_i} \sum_{l=0}^{N-1} p_l^* (a_l + jb_l) = \frac{1}{2} \left(\frac{\partial}{\partial a_i} - j \frac{\partial}{\partial b_i} \right) \left\{ \sum_{l=0}^{N-1} p_l^* (a_l + jb_l) \right\} = p_i^*$$

$$\frac{\partial}{\partial z_i} \sum_{l=0}^{N-1} p_l^* (a_l + jb_l) = \frac{1}{2} \left(\frac{\partial}{\partial a_i} + j \frac{\partial}{\partial b_i} \right) \left\{ \sum_{l=0}^{N-1} p_l^* (a_l + jb_l) \right\} = 0$$

$$\nabla_{\mathbf{z}} \{\mathbf{z}^H \mathbf{p}\} = \mathbf{0}$$

$$\nabla_{\mathbf{z}^*} \{\mathbf{z}^H \mathbf{p}\} = \mathbf{p}$$

$$\nabla_{\mathbf{z}} \{\mathbf{z}^H \mathbf{A} \mathbf{z}\} = (\mathbf{A} \mathbf{z})^*$$

$$\nabla_{\mathbf{z}^*} \{\mathbf{z}^H \mathbf{A} \mathbf{z}\} = (\mathbf{A} \mathbf{z})$$

Pentru ca punctual stationar respective să fie punct de extrem, hessianul

$$\nabla_{\mathbf{z}\mathbf{z}^*}^2 \{f\} \begin{cases} > 0 \text{ pentru un minim} \\ < 0 \text{ pentru un maxim} \end{cases}$$

unde semnul de inegalitate semnifică ‘*pozitiv semidefinit*’,

respectiv ‘*negativ semidefinit*’.

3.2 ECUAȚIILE WIENER-HOPF

$$\begin{aligned} \frac{\partial}{\partial w_i^*} \left\{ \mathbf{w}^H \mathbf{p} + \mathbf{p}^H \mathbf{w} \right\} &= \\ = \frac{1}{2} \left(\frac{\partial}{\partial a_i} + j \frac{\partial}{\partial b_i} \right) \left\{ \sum_{k=0}^{N-1} (a_k - j b_k) r_{xd}(-k) + \sum_{k=0}^{N-1} (a_k + j b_k) r_{xd}^*(-k) \right\} &= \\ &= r_{xd}(-i) \end{aligned}$$

$$\nabla \left\{ \mathbf{w}^H \mathbf{p} + \mathbf{p}^H \mathbf{w} \right\} = \mathbf{p}$$

3.2 ECUAȚIILE WIENER-HOPF

$$\begin{aligned}
 & \frac{\partial}{\partial w_i^*} \left\{ \mathbf{w}^H \mathbf{R} \mathbf{w} \right\} = \\
 &= \frac{1}{2} \left(\frac{\partial}{\partial a_i} + j \frac{\partial}{\partial b_i} \right) \left\{ \sum_{k=0}^{N-1} \sum_{l=0}^{N-1} (a_k - jb_k)(a_l + jb_l) r_{xx}(l-k) \right\} = \\
 &= \sum_{l=0}^{N-1} w_l r_{xx}(l-i) \\
 & \nabla \left\{ \mathbf{w}^H \mathbf{R} \mathbf{w} \right\} = \mathbf{R} \mathbf{w};
 \end{aligned}$$

$$\nabla J = -\mathbf{p} + \mathbf{R} \mathbf{w} = \mathbf{0}$$

3.2 ECUAȚIILE WIENER-HOPF

Hessianul transformării:

$$\mathbf{H} = \nabla_{\mathbf{w}\mathbf{w}^*}^2 J = \nabla_{\mathbf{w}} \left(\nabla_{\mathbf{w}^*} \right) = \nabla_{\mathbf{w}} (-\mathbf{p} + \mathbf{R}\mathbf{w}) = \mathbf{R}$$

Este pozitiv semidefinit, $J(\mathbf{w})$ reprezintă o suprafață de forma unui paraboloid având un minim J_{\min} pentru $\mathbf{w}=\mathbf{w}_o$ care anulează gradientul

$$\mathbf{R}\mathbf{w}_o = \mathbf{p}$$

$$\sum_{l=0}^{N-1} w_{o,l} r_{xx}(l-i) = r_{xd}(-i), \quad i = 0, \dots, N-1$$

$$\begin{aligned} J_{\min} &= \sigma_d^2 - \mathbf{w}_o^H \mathbf{p} - \mathbf{p}^H \mathbf{w}_o + \mathbf{w}_o^H \mathbf{R} \mathbf{w}_o = \\ &= \sigma_d^2 - \mathbf{w}_o^H \mathbf{p} - \mathbf{p}^H \mathbf{w}_o + \mathbf{w}_o^H \mathbf{p} = \sigma_d^2 - \mathbf{p}^H \mathbf{w}_o = \sigma_d^2 - \mathbf{p}^H \mathbf{R}^{-1} \mathbf{p} \end{aligned}$$

3.3 PRINCIPIUL ORTOGONALITĂȚII

Pentru filtrul optim:

$$y_o(n) = \mathbf{w}_o^H \mathbf{x}(n)$$

$$e_o(n) = d(n) - \mathbf{w}_o^H \mathbf{x}(n)$$

$$\mathbb{E}\{\mathbf{x}(n)e_o^*(n)\} = \mathbb{E}\{\mathbf{x}(n)d_o^*(n)\} - \mathbb{E}\{\mathbf{x}(n)\mathbf{x}^H(n)\mathbf{w}_o\}$$

$$\mathbb{E}\{\mathbf{x}(n)e_o^*(n)\} = \mathbf{p} - \mathbf{R}\mathbf{w}_o = \mathbf{0}$$


$$\begin{aligned} \mathbb{E}\{\mathbf{x}(n)e_o^*(n)\} &= \mathbf{0} \\ \mathbb{E}\{\mathbf{x}(n-k)e_o^*(n)\} &= 0, \quad k = 0, \dots, N-1 \end{aligned}$$

- eroarea este ortogonală pe eşantioanele intrării.

3.3 PRINCIPIUL ORTOGONALITĂȚII


$$E\{y_o(n)e_o^*(n)\} = 0$$

- ieșirea $y_o(n)$ și eroarea $e_o(n)$ corespunzătoare sunt ortogonale



4. PREDICTION LINIARĂ

4.1 Predicția înainte (directă)



$x(n)$ un proces aleator staționar cu valoare medie nulă.

Se cunosc N eşantioane anterioare

$$x(n-1), x(n-2), \dots, x(n-N) \Rightarrow X_{n-1}$$

Pe baza lor se dorește o estimare a lui $x(n)$:

$$\hat{x}(n|X_{n-1}) = \sum_{k=1}^N w_k^* x(n-k) = \mathbf{w}^H \mathbf{x}(n-1),$$

$$\mathbf{x}(n-1) = [x(n-1), x(n-2), \dots, x(n-N)]^T, \quad \mathbf{w} = [w_1, w_2, \dots, w_N]^T$$

4.1 Predicția înainte (directă)

eroarea de predicție:

$$e_N^f(n) = x(n) - \hat{x}(n|X_{n-1})$$

Puterea erorii de predicție:

$$P_N = E\left\{ |e_N^f(n)|^2 \right\}.$$

4.1 Predicția înainte (directă)

Analogii cu problema filtrării optimale:

$$d(n) \Rightarrow x(n)$$

$$\mathbf{x}(n) \Rightarrow \mathbf{x}(n-1)$$

$$e(n) \Rightarrow e_N^f(n)$$

$$J_{\min} \Rightarrow P_N$$

$$\mathbf{R} \Rightarrow E\{\mathbf{x}(n-1)\mathbf{x}^H(n-1)\} = \mathbf{R}$$

$$\mathbf{p} \Rightarrow \mathbf{r} = E\{\mathbf{x}(n-1)x^*(n)\} = [r_{xx}(-1), r_{xx}(-2), \dots, r_{xx}(-N)]^T$$

$$\sigma_d^2 = E\{|x(n)|^2\} = \sigma_x^2 = r_{xx}(0)$$

4.1 Predicția înainte (directă)

Se pot prelua direct următoarele rezultate:

- ***ecuația Wiener-Hopf (ecuația normală)***

$$\mathbf{R}\mathbf{w}_o = \mathbf{r} \quad \text{sau} \quad \mathbf{w}_o = \mathbf{R}^{-1}\mathbf{r}$$

- ***principiul ortogonalității***


$$E\left\{\mathbf{x}(n-1)e_N^{f*}(n)\right\} = \mathbf{0} \quad E\left\{\hat{x}(n|X_{n-1})e_N^{f*}(n)\right\} = 0$$

- ***Expresia puterii erorii de predicție***, în cazul coeficienților optimi,

$$P_N = \sigma_x^2 - \mathbf{r}^H \mathbf{w}_o = r_{xx}(0) - \mathbf{r}^H \mathbf{w}_o = r(0) - \mathbf{r}^H \mathbf{w}_o$$

4.1 Predicția înainte (directă)

Filtrul predictor:




4.1 Predicția înainte (directă)

Filtrul erorii de predicție înainte

$$e_N^f(n) = x(n) - \sum_{k=1}^N w_{o,k}^* x(n-k) = \sum_{k=0}^N a_{N,k} x(n-k)$$

unde

$$a_{N,k} = \begin{cases} 1, & k = 0 \\ -w_{o,k}^*, & k = 1, \dots, N \end{cases}$$



4.1 Predicția înainte (directă)

Ecuațiile Wiener-Hopf extinse:

$$\begin{aligned}\mathbf{r} - \mathbf{R}\mathbf{w}_o &= 0 \\ r(0) - \mathbf{r}^H \mathbf{w}_o &= P_N\end{aligned}$$

$$\begin{bmatrix} r(0) & \mathbf{r}^H \\ \mathbf{r} & \mathbf{R} \end{bmatrix} \begin{bmatrix} 1 \\ -\mathbf{w}_o \end{bmatrix} = \begin{bmatrix} P_N \\ \mathbf{0} \end{bmatrix}$$

4.1 Predicția înainte (directă)

$$\begin{bmatrix} r(0) & \mathbf{r}^H \\ \mathbf{r} & \mathbf{R} \end{bmatrix} \begin{bmatrix} 1 \\ -\mathbf{w}_o \end{bmatrix} = \begin{bmatrix} P_N \\ \mathbf{0} \end{bmatrix}$$

Sau

$$\mathbf{R}_{N+1} \mathbf{a}_N^* = \begin{bmatrix} P_N \\ 0 \end{bmatrix}$$

unde

$$\mathbf{a}_N = \begin{bmatrix} 1 \\ -\mathbf{w}_o^* \end{bmatrix}$$

și \mathbf{R}_{N+1} este matricea de autocorelație extinsă, de dimensiuni $(N+1) \times (N+1)$


4.2. PREDICTION ÎNAPOI (INVERSĂ)

Se cunosc:

$$x(n), x(n-1), \dots, x(n-N+1) \Rightarrow X_n$$

Se dorește un estimat al lui

$$x(n-N)$$



4.2. PREDICTION ÎNAPOI (INVERSĂ)

$$\hat{x}(n-N|X_n) = \sum_{k=1}^N g_k^* x(n-k+1)$$

Eroarea de predicție:

$$e_N^b(n) = x(n-N) - \hat{x}(n-N|X_n)$$
$$\mathbf{g} = [g_1, g_2, \dots, g_N]^T$$

Puterea erorii de predicție

$$P_N = E\left\{ |e_N^b(n)|^2 \right\}$$

4.2. PREDICTIONA ÎNAPOI (INVERSĂ)

Analogii cu problema filtrării optimale:

$$d(n) \Rightarrow x(n - N)$$

$$\begin{aligned} \mathbf{w}_o &\Rightarrow \mathbf{g}_o \\ e(n) &\Rightarrow e_N^b(n) \end{aligned}$$

$$J_{\min} \Rightarrow P_N$$

$$\mathbf{p} \Rightarrow \mathbf{r}^{B^*} = \mathbf{E}\left\{\mathbf{x}(n)x^*(n - N)\right\} = [r_{xx}(N), r_{xx}(N-1), \dots, r_{xx}(1)]^T.$$

4.2. PREDICTION ÎNAPOI (INVERSĂ)

Se preiau:

- Ecuația normală

$$\mathbf{R}\mathbf{g} = \mathbf{r}^{B*}$$

- Puterea erorii de predicție

$$P_N = r(0) - \mathbf{r}^{BT} \mathbf{g}$$

- Prințipiu ortogonalității

$$\mathbf{E}\{\mathbf{x}(n)e_N^{b*}(n)\} = \mathbf{0}$$


sau

$$\mathbf{E}\{x(n-k)e_N^{b*}(n)\} = 0, \quad k = 0, 1, \dots, N-1$$

4.2. PREDICTIONA ÎNAPOI (INVERSĂ)

Filtrul ce realizează predicția inversă

$$\hat{x}(n - N | X_n) = \sum_{k=1}^N g_k^* x(n - k + 1)$$




4.2. PREDICTIONA ÎNAPOI (INVERSĂ)

Filtrul erorii de predicție înapoi.

$$e_N^b(n) = x(n-N) - \sum_{k=1}^N g_k^* x(n-k+1) = \sum_{k=0}^N c_{N,k} x(n-k)$$

unde

$$c_{N,k} = \begin{cases} -g_{k+1}^* & k = 0, \dots, N-1 \\ 1, & k = N \end{cases}$$



4.2. PREDICTION ÎNAPOI (INVERSĂ)

Ecuațiile Wiener-Hopf extinse pentru predicția inversă

$$-\mathbf{R}\mathbf{g} + \mathbf{r}^{B*} = \mathbf{0}$$

$$\mathbf{r}(0) - \mathbf{r}^{BT}\mathbf{g} = P_N$$

$$\begin{bmatrix} \mathbf{R} & \mathbf{r}^{B*} \\ \mathbf{r}^{BT} & \mathbf{r}(0) \end{bmatrix} \begin{bmatrix} -\mathbf{g} \\ 1 \end{bmatrix} = \begin{bmatrix} \mathbf{0} \\ P_N \end{bmatrix}$$

sau

$$\mathbf{R}_{N+1}\mathbf{c}_N^* = \begin{bmatrix} \mathbf{0} \\ P_N \end{bmatrix}$$

unde

$$\mathbf{c}_N = \begin{bmatrix} -\mathbf{g}^* \\ 1 \end{bmatrix}$$

4.2. PREDICTION INVERSE (INVERSE)

Relație între coeficienții filtrelor de predicție directă și inversă

$$\mathbf{R}\mathbf{g} = \mathbf{r}^{B*} \Rightarrow \mathbf{R}^T \mathbf{g}^B = \mathbf{r}^* \Rightarrow \mathbf{R}^H \mathbf{g}^{B*} = \mathbf{r} \Rightarrow \mathbf{R}\mathbf{g}^{B*} = \mathbf{r}$$

$$\mathbf{g}^{B*} = \mathbf{w} \Leftrightarrow \mathbf{w}^{B*} = \mathbf{g}$$

sau

$$g_k = w_{N-k+1}^*, \quad k = 1, \dots, N$$

$$\mathbf{c}_N = \begin{bmatrix} -\mathbf{g}^* \\ 1 \end{bmatrix} = \begin{bmatrix} -\mathbf{w}^B \\ 1 \end{bmatrix} \quad \mathbf{a}_N = \begin{bmatrix} 1 \\ -\mathbf{w}^* \end{bmatrix}$$

$$\mathbf{c}_N = \mathbf{a}_N^{B*} \quad c$$

sau

$$c_{N,k} = a_{N,N-k}^*, \quad k = 0, \dots, N$$

$$\mathbf{r}^{BT} \mathbf{g} = \mathbf{r}^T \mathbf{g}^B = (\mathbf{r}^T \mathbf{g}^B)^* = \mathbf{r}^H \mathbf{g}^{B*} = \mathbf{r}^H \mathbf{w} \Rightarrow$$

puterile erorilor de predicție sunt identice în cele două cazuri.

4.3 ALGORITMI EFICIENȚI DE REZOLVARE A ECUAȚIEI NORMALE A FILTRĂRII LINIARE OPTIMALE

Ecuația normală este un sistem $N \times N$

Rezolvat prin metoda Gauss rezultă o complexitate de tip $O(N^3)$

Algoritm rapid ar însemna $O(N)$

4.3.1 Algoritmul Levinson-Durbin

Vom căuta o constantă k_m , astfel încât să fie posibilă o relație de forma:

$$\mathbf{a}_m = \begin{bmatrix} \mathbf{a}_{m-1} \\ 0 \end{bmatrix} + k_m \begin{bmatrix} 0 \\ \mathbf{a}_{m-1}^{B*} \end{bmatrix}$$

sau

$$\mathbf{a}_m^* = \begin{bmatrix} \mathbf{a}_{m-1}^* \\ 0 \end{bmatrix} + k_m^* \begin{bmatrix} 0 \\ \mathbf{a}_{m-1}^B \end{bmatrix}$$

$$a_{m,k} = a_{m-1,k} + k_m a_{m-1,m-k}^*, \quad k = 0, \dots, m$$

$$a_{m-1,0} = 1, \quad a_{m-1,m} = 0$$

4.3.1 Algoritmul Levinson-Durbin

$$\mathbf{a}_m^* = \begin{bmatrix} \mathbf{a}_{m-1}^* \\ 0 \end{bmatrix} + k_m^* \begin{bmatrix} 0 \\ \mathbf{a}_{m-1}^B \end{bmatrix}$$

$$\mathbf{R}_{m+1} \mathbf{a}_m^* = \begin{bmatrix} P_m \\ \mathbf{0}_m \end{bmatrix}$$

$$\mathbf{R}_{m+1} = \begin{bmatrix} \mathbf{R}_m & \mathbf{r}_m^{B*} \\ \mathbf{r}_m^{BT} & r(0) \end{bmatrix}$$

$$\mathbf{R}_{m+1} \begin{bmatrix} \mathbf{a}_{m-1}^* \\ 0 \end{bmatrix} = \begin{bmatrix} \mathbf{R}_m & \mathbf{r}_m^{B*} \\ \mathbf{r}_m^{BT} & r(0) \end{bmatrix} \begin{bmatrix} \mathbf{a}_{m-1}^* \\ 0 \end{bmatrix} = \begin{bmatrix} \mathbf{R}_m \mathbf{a}_{m-1}^* \\ \mathbf{r}_m^{BT} \mathbf{a}_{m-1}^* \end{bmatrix}$$

4.3.1 Algoritmul Levinson-Durbin

$$\mathbf{R}_{m+1} \begin{bmatrix} \mathbf{a}_{m-1}^* \\ 0 \end{bmatrix} = \begin{bmatrix} \mathbf{R}_m \mathbf{a}_{m-1}^* \\ \mathbf{r}_m^{BT} \mathbf{a}_{m-1}^* \end{bmatrix} = \begin{bmatrix} P_{m-1} \\ \mathbf{0}_{m-1} \end{bmatrix} = \Delta_{m-1}$$

Notăm

$$\Delta_{m-1} = \mathbf{r}_m^{BT} \mathbf{a}_{m-1}^* = \sum_{k=0}^{m-1} a_{m-1,k}^* r(k-m)$$

și având în vedere forma extinsă a ecuațiilor Wiener-Hopf pentru predictorul de ordin $m-1$,

$$\mathbf{R}_{m+1} \begin{bmatrix} \mathbf{a}_{m-1}^* \\ 0 \end{bmatrix} = \begin{bmatrix} P_{m-1} \\ \mathbf{0}_{m-1} \\ \Delta_{m-1} \end{bmatrix}$$

4.3.1 Algoritmul Levinson-Durbin


$$\mathbf{a}_m^* = \begin{bmatrix} \mathbf{a}_{m-1}^* \\ 0 \end{bmatrix} + k_m^* \begin{bmatrix} 0 \\ \mathbf{a}_{m-1}^B \end{bmatrix}$$

$$\mathbf{R}_{m+1} \begin{bmatrix} 0 \\ \mathbf{a}_{m-1}^B \end{bmatrix} = \begin{bmatrix} r(0) & \mathbf{r}_m^H \\ \mathbf{r}_m & \mathbf{R}_m \end{bmatrix} \begin{bmatrix} 0 \\ \mathbf{a}_{m-1}^B \end{bmatrix} = \begin{bmatrix} \mathbf{r}_m^H \mathbf{a}_{m-1}^B \\ \mathbf{R}_m \mathbf{a}_{m-1}^B \end{bmatrix}$$

$$\mathbf{r}_m^H \mathbf{a}_{m-1}^B = \Delta_{m-1}^*, \quad \mathbf{R}_m \mathbf{a}_{m-1}^B = \mathbf{R}_m \mathbf{c}_{m-1}^* = \begin{bmatrix} \mathbf{0}_{m-1} \\ P_{m-1} \end{bmatrix}$$

$$\mathbf{R}_{m+1} \begin{bmatrix} 0 \\ \mathbf{a}_{m-1}^B \end{bmatrix} = \begin{bmatrix} \Delta_{m-1}^* \\ \mathbf{0}_{m-1} \\ P_{m-1} \end{bmatrix}$$

4.3.1 Algoritmul Levinson-Durbin

$$\begin{bmatrix} P_m \\ \mathbf{0}_m \end{bmatrix} = \begin{bmatrix} P_{m-1} \\ \mathbf{0}_{m-1} \end{bmatrix} + k_m^* \begin{bmatrix} \Delta_{m-1}^* \\ \mathbf{0}_{m-1} \\ P_{m-1} \end{bmatrix}$$
$$P_m = P_{m-1} + k_m^* \Delta_{m-1}^* ; \quad \mathbf{0} = \Delta_{m-1} + k_m^* P_{m-1}$$


4.3.1 Algoritmul Levinson-Durbin

$$P_m = P_{m-1} + k_m^* \Delta_{m-1}^* ; \quad 0 = \Delta_{m-1} + k_m^* P_{m-1}$$

$$P_m = P_{m-1} \left(1 - |k_m|^2 \right)$$

$$P_m \geq 0 \Rightarrow |k_m| \leq 1$$

$$e_0^f(n) = e_0^b(n) = x(n); \quad P_0 = r(0)$$

$$P_N = P_0 \prod_{m=1}^N \left(1 - |k_m|^2 \right)$$

4.3.1 Algoritmul Levinson-Durbin

Observații

- Puterea erorii de predicție scade o dată cu creșterea ordinului predictorului.
- Coeficienții k_m - *coeficienți de reflexie*

Pentru $k=m$,

$$k_m = a_{m,m}$$

- Se poate ușor arăta, folosind definițiile și principiul ortogonalității, că:

$$\Delta_{m-1} = E \left\{ e_{m-1}^b(n-1) e_{m-1}^{f*}(n) \right\}$$

unde $e_{m-1}^f(n)$ - răspunsul filtrului erorii de predicție directă de ordinul $m-1$, pentru secvența de intrare $x(n), x(n-1), \dots, x(n-m+1)$,

$e_{m-1}^b(n-1)$ - răspunsul filtrului erorii de predicție inversă, de ordinul $m-1$, la secvența $x(n-1), x(n-2), \dots, x(n-m)$.

4.3.1 Algoritmul Levinson-Durbin

Observații

- Având în vedere că:

$$e_0^f(n) = e_0^b(n) = x(n)$$
$$\Delta_0 = E\{e_0^b(n-1)e_0^{f*}(n)\} = E\{x(n-1)x^*(n)\} = r(-1) = r^*(1)$$

- Cunoscând Δ_0 și P_0 se pot calcula, folosind relațiile de recurență

$$k_1 = -\frac{\Delta_0^*}{P_0} = -\frac{r(1)}{r(0)}; \quad P_1 = r(0) - \frac{|r(1)|^2}{r(0)}$$

4.3.1 Algoritmul Levinson-Durbin

$$P_0 = r(0); \Delta_0 = r^*(1)$$

for $m = 1 : 1 : N$

$$k_m = -\frac{\Delta_{m-1}^*}{P_{m-1}}$$

$$P_m = P_{m-1} \left(1 - |k_m|^2\right)$$

for $k = 1 : 1 : m$

$$a_{m,k} = a_{m-1,k} + k_m a_{m-1,m-k}^*$$

end

$$\Delta_m = \sum_{k=0}^m a_{m,k}^* r(k-m-1)$$

end

4.3.1 Algoritmul Levinson-Durbin

Complexitatea aritmetică a algoritmului

În pasul m al algoritmului trebuie efectuate:

- o împărțire;
- $2m+1$ înmulțiri (două pentru calculul lui P_m , $m-1$ pentru reactualizarea coeficienților $a_{m,k}$, și m pentru calculul lui Δ_m).
- $2m$ adunări.

Pentru efectuarea întregului algoritm, rezultă

$$\sum_{m=1}^N (2m + 2) = N^2 + 3N$$

înmulțiri / împărțiri și

$$\sum_{m=1}^N (2m) = N^2 + N$$

Dacă se utilizează o singură unitate aritmetică și aceasta efectuează o operație aritmetică într-o unitate de timp, timpul total de calcul este $O(N^2)$.

Când se dispune de N unități aritmetice ce pot lucra în paralel timpul de calcul este $O(N \log_2 N)$

4.3.2 Algoritmul Schur - definirea funcțiilor de tip ‘f’

Răspunsul filtrului erorii de predicție de ordin m la secvența de autocorelație

$$y_m^f(i) = \sum_{k=0}^m a_{m,k} r_{xx}(i-k) = a_{m,i} * r_{xx}(i)$$

Conform ecuației Wiener_Hopf pentru predictorul de ordin m

$$\mathbf{R}_{m+1} \mathbf{a}_m^* = \begin{bmatrix} P_m \\ \mathbf{0} \end{bmatrix}$$

Elementele matricei de autocorelație sunt

$$R_{i,k} = r_{xx}(k-i), \quad k, i = 0, 1, \dots, m$$

4.3.2 Algoritmul Schur –

definirea funcțiilor de tip ‘f’

$$\sum_{k=0}^m R_{i,k} a_{m,k}^* = 0, \quad \rightarrow \quad \sum_{k=0}^m a_{m,k}^* r_{xx}(k-i) = 0, \quad i = 1, \dots, m$$

$$\boxed{\sum_{k=0}^m a_{m,k} r_{xx}(i-k) = 0, \quad i = 1, \dots, m}$$

$$y_m^f(i) = 0, \quad i = 1, \dots, m$$

4.3.2 Algoritmul Schur – definirea funcțiilor de tip ‘f’

$$\sum_{k=0}^m R_{0,k} a_{m,k}^* = P_m, \rightarrow \sum_{k=0}^m a_{m,k}^* r_{xx}(k) = P_m, \quad i = 0$$

rezultă că

$$y_m^f(0) = \sum_{k=0}^m a_{m,k} r_{xx}(-k) = P_m$$

4.3.2 Algoritmul Schur – definirea funcțiilor de tip ‘b’

Pornind de la predicția inversă

$$y_m^b(i) = \sum_{k=0}^m c_{m,k} r_{xx}(i-k) = c_{m,i} * r_{xx}(i)$$

Dar

$$c_{m,k} = a_{m,m-k}^*$$

așa încât

$$y_m^b(i) = y_m^{f*}(m-i)$$

$$y_m^b(i) = 0, \quad i = 0, \dots, m-1$$

$$y_m^b(m) = P_m$$

4.3.2 Algoritmul Schur – relații de recurență

Din relațiile

$$\begin{aligned}a_{m,k} &= a_{m-1,k} + k_m a_{m-1,m-k}^* = a_{m-1,k} + k_m c_{m-1,k-1} \\c_{m,k} &= k_m^* a_{m-1,k} + c_{m-1,k-1}\end{aligned}$$

se obțin niște relații de recurență asemănătoare pentru aceste funcții:

$$\begin{aligned}y_m^f(i) &= y_{m-1}^f(i) + k_m y_{m-1}^b(i-1) \\y_m^b(i) &= k_m^* y_{m-1}^f(i) + y_{m-1}^b(i-1)\end{aligned}$$

cu condițiile inițiale:

$$y_0^f(i) = y_0^b(i) = r_{xx}(i)$$

4.3.2 Algoritmul Schur – coeficientul de reflexie

În particular

$$y_m^f(m) = 0 \Rightarrow y_{m-1}^f(m) + k_m y_{m-1}^b(m-1) = 0$$

de unde

$$k_m = -\frac{y_{m-1}^f(m)}{y_{m-1}^b(m-1)}$$

4.3.2 Algoritmul Schur

for $k = 0 : N$

$$y_0^f(k) = y_0^b(k) = r_{xx}(k)$$

end

for $m = 1 : N$

$$k_m = -\frac{y_{m-1}^f(m)}{y_{m-1}^b(m-1)}$$

for $i = m + 1 : N$

$$y_m^f(i) = y_{m-1}^f(i) + k_m y_{m-1}^b(i-1)$$

end

for $i = m : N$

$$y_m^b(i) = k_m^* y_{m-1}^f(i) + y_{m-1}^b(i-1)$$

end

end

$$P_N = y_N^b(N)$$

4.3.2 Algoritmul Schur – complexitate aritmetică

În pasul m se efectuează:

o împărțire, pentru calculul lui k_m ;

$N-m$ înmulțiri și $N-m$ adunări, în primul ciclu după i ;

$N-m+1$ înmulțiri și $N-m+1$ adunări, în al doilea ciclu după i .

Rezultă un număr de $2N-2m+2$ înmulțiri / împărțiri și $2N-2m+1$ adunări, deci în total

$$\sum_{m=1}^N (2N - 2m + 2) = N^2 + N$$

înmulțiri / împărțiri și

$$\sum_{m=1}^N (2N - 2m + 1) = N^2$$

adunări.

4.3.2 Algoritmul Schur – Modalitate practică de calcul

Inițializarea algoritmului. Se constituie “matricea generatoare”

$$\mathbf{G}_0 = \begin{bmatrix} 0 & y_0^f(1) & \cdots & y_0^f(N) \\ y_0^b(0) & y_0^b(1) & \cdots & y_0^b(N) \end{bmatrix}$$

sau

$$\mathbf{G}_0 = \begin{bmatrix} 0 & r_{xx}(1) & r_{xx}(2) & \dots & r_{xx}(N) \\ r_{xx}(0) & r_{xx}(1) & r_{xx}(2) & \dots & r_{xx}(N) \end{bmatrix}$$

4.3.2 Algoritmul Schur – Modalitate practică de calcul

Prin deplasarea spre dreapta cu o unitate a liniei a doua se obține

$$\mathbf{G}'_0 = \begin{bmatrix} 0 & y_0^f(1) & \cdots & y_0^f(N) \\ 0 & y_0^b(0) & \cdots & y_0^b(N-1) \end{bmatrix}$$

sau

$$\mathbf{G}'_0 = \begin{bmatrix} 0 & r_{xx}(1) & r_{xx}(2) & \dots & r_{xx}(N) \\ 0 & r_{xx}(0) & r_{xx}(1) & \dots & r_{xx}(N-1) \end{bmatrix}$$

Raportul elementelor coloanei a doua, cu semnul schimbat,
determină primul coeficient de reflexie, k_1 .

$$k_1 = -\frac{y_0^f(1)}{y_0^b(0)}$$

4.3.2 Algoritmul Schur – Modalitate practică de calcul

Se constituie matricea

$$\mathbf{K}_1 = \begin{bmatrix} 1 & k_1 \\ k_1^* & 1 \end{bmatrix}$$

Se calculează

$$\mathbf{K}_1 \mathbf{G}'_0 = \begin{bmatrix} 1 & k_1 \\ k_1^* & 1 \end{bmatrix} \begin{bmatrix} 0 & y_0^f(1) & \cdots & y_0^f(N) \\ 0 & y_0^b(0) & \cdots & y_0^b(N-1) \end{bmatrix}$$

$$\mathbf{G}_1 = \mathbf{K}_1 \mathbf{G}'_0 = \begin{bmatrix} 0 & 0 & y_1^f(2) & \cdots & y_1^f(N) \\ 0 & y_1^b(1) & y_1^b(2) & \cdots & y_1^b(N) \end{bmatrix}$$

unde s-au avut în vedere relațiile de recurență și faptul că $y_1^f(1) = 0$.

4.3.2 Algoritmul Schur – Modalitate practică de calcul


În continuare se repetă ultimele trei operații, deci în pasul m :

- Se formează \mathbf{G}'_m din \mathbf{G}_m prin deplasarea spre dreapta cu o poziție a liniei a doua.
- Se calculează k_{m+1} ca raport cu semnul schimbat a elementelor coloanei $m+2$ și se formează matricea \mathbf{K}_{m+1} .
- Se calculează

$$\mathbf{G}_{m+1} = \mathbf{K}_{m+1} \mathbf{G}'_m$$

Procedeul se reia până se calculează toți coeficienții de reflexie.


4.3.2 Algoritmul Schur – Variantă paralel de implementare a algoritmului Schur



4.3.2 Algoritmul Schur –


Variantă paralel de implementare a algoritmului Schur

F2,...,FN,B1,...,BN



a.

F1



b.

4.4 FILTRELE ERORII DE PREDICTION

4.4.1 Proprietăți ale filtrelor erorii de predicție

Vom nota funcțiile de transfer ale filtrelor erorii de predicție directă și inversă de ordinul m cu:

$$H_m^f(z) = \sum_{k=0}^m a_{m,k} z^{-k}; \quad H_m^b(z) = \sum_{k=0}^m c_{m,k} z^{-k} = \sum_{k=0}^m a_{m,m-k}^* z^{-k}$$

1) Între funcțiile de transfer ale celor două filtre există relația

$$H_m^b(z) = z^{-m} H_m^{f*} \left(\frac{1}{z^*} \right)$$

2) *Caracteristicile amplitudine-frecvență* ale celor două filtre sunt identice.

$$H_m^b(e^{j\omega}) = e^{-jm\omega} H_m^{f*}(e^{j\omega}) \Rightarrow |H_m^b(e^{j\omega})| = |H_m^f(e^{j\omega})|$$

4.4 FILTRELE ERORII DE PREDICTION

4.4.1 Proprietăți ale filtrelor erorii de predicție

3) *Relație de recurență.* Având în vedere formulele

$$a_{m,k} = a_{m-1,k} + k_m a_{m-1,m-k}^*, \quad k = 0, \dots, m$$

rezultă:

$$H_m^f(z) = H_{m-1}^f(z) + k_m z^{-1} H_{m-1}^b(z)$$

4.4 FILTRELE ERORII DE PREDICTION

4.4.1 Proprietăți ale filtrelor erorii de predicție

4) *Filtrul erorii de predicție directă este de fază minimă.* Pentru demonstrație vom avea în vedere faptul că $|k_m| < 1$, ceea ce, ținând seama și de proprietatea 2 conduce la:

$$|k_m z^{-1} H_{m-1}^b(z)| < |H_{m-1}^b(z)| = |H_{m-1}^f(z)| \quad \text{pe } |z| = 1$$

Teorema lui Rouché:

Dacă două funcții $F(z)$, $G(z)$, sunt analitice pe conturul C din planul z și în interiorul conturului, și $|G(z)| < |F(z)|$ pe contur, atunci funcția $F(z)+G(z)$ are același număr de zerouri în interiorul conturului C ca și $F(z)$.

4.4 FILTRELE ERORII DE PREDICTION

4.4.1 Proprietăți ale filtrelor erorii de predicție

Fie conturul C cercul $|z|=1$ și vom aplica teorema aceasta pentru funcțiile:

$$F(z) = H_{m-1}^f(z), \quad G(z) = k_m z^{-1} H_{m-1}^b(z)$$

C în sens direct trigonometric $\Rightarrow \text{int}\{C\} = \{z|<1\}$

C în sens invers trigonometric $\Rightarrow \text{int}\{C\} = \{z|>1\}$

Conform teoremei enunțate, dacă $H_{m-1}^f(z)$ nu are zerouri în $|z|>1$,

de aceeași proprietate se bucură și $H_m^f(z)$. Cum $H_0^f(z)=1$, rezultă

prin inducție completă că $H_m^f(z)$ nu are zerouri în afara cercului $|z|=1$.

4.4 FILTRELE ERORII DE PREDICTION

4.4.1 Proprietăți ale filtrelor erorii de predicție

5) *Filtrul erorii de predicție inversă este de fază maximă* (are toate zerourile în exteriorul cercului $|z| = 1$).

Dacă se exprimă $H_m^f(z)$ sub forma

$$H_m^f(z) = \prod_{i=1}^m \left(1 - z_i z^{-1}\right), \quad |z_i| < 1$$

având în vedere proprietatea 1, rezultă

$$H_m^b(z) = z^{-m} \prod_{i=1}^m \left(1 - z_i^* z\right) = \prod_{i=1}^m \left(z^{-1} - z_i^*\right)$$

Nulurile acestei funcții de transfer sunt de forma $1/z_i^*$, $i=1, \dots, m$, și sunt evident situate în $|z| > 1$, simetric față de z_i în raport cu cercul $|z| = 1$.

4.4 FILTRELE ERORII DE PREDICTION

4.4.2 Forma "latice" de realizare a filtrului erorii de predictie

Relatii de recurență pentru eroarea de predicție

$$e_m^f(n) = \mathbf{a}_m^T \mathbf{x}_{m+1}(n) = \left(\begin{bmatrix} \mathbf{a}_{m-1} \\ 0 \end{bmatrix} + k_m \begin{bmatrix} 0 \\ \mathbf{a}_{m-1}^{BH} \end{bmatrix} \right)^T \mathbf{x}_{m+1}(n) =$$

$$= \left[\mathbf{a}_{m-1}^T, 0 \begin{bmatrix} \mathbf{x}_m(n) \\ x(n-m) \end{bmatrix} \right] + k_m \left[0, \mathbf{a}_{m-1}^{BH} \begin{bmatrix} x(n) \\ \mathbf{x}_m(n-1) \end{bmatrix} \right] =$$

$$= \mathbf{a}_{m-1}^T \mathbf{x}_m(n) + k_m \mathbf{a}_{m-1}^{BH} \mathbf{x}_m(n-1)$$

$$\mathbf{a}_{m-1}^{BH} \mathbf{x}_m(n-1) = \mathbf{c}_{m-1}^T \mathbf{x}_m(n-1) = e_{m-1}^b(n-1)$$

$$e_m^f(n) = e_{m-1}^f(n) + k_m e_{m-1}^b(n-1)$$

4.4 FILTRELE ERORII DE PREDIȚIE

4.4.2 Forma "latice" de realizare a filtrului erorii de predicție

În mod asemănător se găsește:


$$e_m^b(n) = e_{m-1}^b(n-1) + k_m^* e_{m-1}^f(n-1)$$

Cele două relații pot fi grupate


$$\begin{bmatrix} e_m^f(n) \\ e_m^b(n) \end{bmatrix} = \begin{bmatrix} 1 & k_m \\ k_m^* & 1 \end{bmatrix} \begin{bmatrix} e_{m-1}^f(n) \\ e_{m-1}^b(n-1) \end{bmatrix}$$

4.4 FILTRELE ERORII DE PREDICTION

$$\begin{bmatrix} e_m^f(n) \\ e_m^b(n) \end{bmatrix} = \begin{bmatrix} 1 & k_m \\ k_m^* & 1 \end{bmatrix} \begin{bmatrix} e_{m-1}^f(n) \\ e_{m-1}^b(n-1) \end{bmatrix}$$



4.4 FILTRELE ERORII DE PREDICTION



4.4 FILTRELE ERORII DE PREDICTION

Se poate pune problema calculului coeficienților k_k , cunoscând $a_{N,1}, \dots, a_{N,N}$. Pentru aceasta vom porni de la ecuația:

$$a_{m,k} = a_{m-1,k} + k_m a_{m-1,m-k}^*, \quad k = 0, 1, \dots, m$$

căreia îi vom alătura ecuația obținută din aceasta prin conjugare complexă și înlocuind k cu $m-k$. Rezultă sistemul:

$$\begin{aligned} a_{m,k} &= a_{m-1,k} + k_m a_{m-1,m-k}^* \\ a_{m,m-k}^* &= k_m^* a_{m-1,k} + a_{m-1,m-k}^* \end{aligned}$$

din care se calculează $a_{m-1,k}$,

$$a_{m-1,k} = \frac{a_{m,k} - k_m a_{m,m-k}^*}{1 - |k_m|^2} = \frac{a_{m,k} - a_{m,m} a_{m,m-k}^*}{1 - |a_{m,m}|^2}$$

4.4 FILTRELE ERORII DE PREDICTION

Cunoscând setul de coeficienți corespunzători predictorului de ordin N , $\{a_{N,k}\}$, se trece, cu formula de mai sus, la cei corespunzători predictorului de ordin $N-1$, $\{a_{N-1,k}\}$ și se determină $k_{m-1}=a_{m-1,m-1}$, și aşa mai departe până la $N=1$.

4.4 FILTRELE ERORII DE PREDICTION

```
for j = 0 : 1 : N
```

$$a_{N,j} = a_j$$

```
end
```

```
for i = N : -1 : 2
```

$$k_i = a_{i,i}$$

```
for j = 1 : 1 : i - 1
```

$$a_{i-1,j} = \frac{a_{i,j} - k_i a_{i,i-j}^*}{1 - |k|_i^2}$$

```
end
```

```
end
```

$$k_1 = a_{1,1}$$

4.4 FILTRELE ERORII DE PREDICTION

Cunoscând setul de coeficienți corespunzători predictorului de ordin N , $\{a_{N,k}\}$, se trece, cu formula de mai sus, la cei corespunzători predictorului de ordin $N-1$, $\{a_{N-1,k}\}$ și se determină $k_{m-1}=a_{m-1,m-1}$, și aşa mai departe până la $N=1$.

Problema inversă – se cunosc coeficienții de reflexie (de exemplu s-au determinat cu algoritmul Schur) și se doresc coeficienții filtrului erorii de predicție în forma transversală.

Se formează în sens invers, de la filtrul de ordinul 1, pentru care se cunosc $a_{1,0} = 1$, $a_{1,1} = k_1$ și se mărește succesiv ordinul.

4.4 FILTRELE ERORII DE PREDICTION

```
a1,1 = k1, a1,0 = 1  
for i = 2:1:N  
    ai,i = ki, ai,0 = 1  
    for j = 1:1:i-1  
        ai,j = ai-1,j + kiai-1,i-j  
    end  
end  
for j = 0:1:N  
    aj = aN,j  
end
```

4.4 FILTRELE ERORII DE PREDICTION

O proprietate remarcabilă a structurii latice este aceea că se poate mări ordinul predictorului, adăugând pur și simplu încă o celulă, fără a modifica în rest structura existentă. Faptul că toate celulele au aceeași structură este favorabil din punctul de vedere al posibilităților de integrare pe scară foarte largă.