


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 notațiile

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

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

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

3.1 CRITERIUL DE OPTIMIZARE

Funcție cost: *eroarea medie pătratică*

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

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

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

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

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

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

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

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

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

∇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.

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

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

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

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

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

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

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

Pentru ca punctual staționar 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

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

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

3.2 ECUAȚIILE WIENER-HOPF

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

3.2 ECUAȚIILE WIENER-HOPF

Hessianul transformării:

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

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:

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

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

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

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


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

- *eroarea este ortogonală pe eșantioanele intrării.*

3.3 PRINCIPIUL ORTOGONALITĂȚII

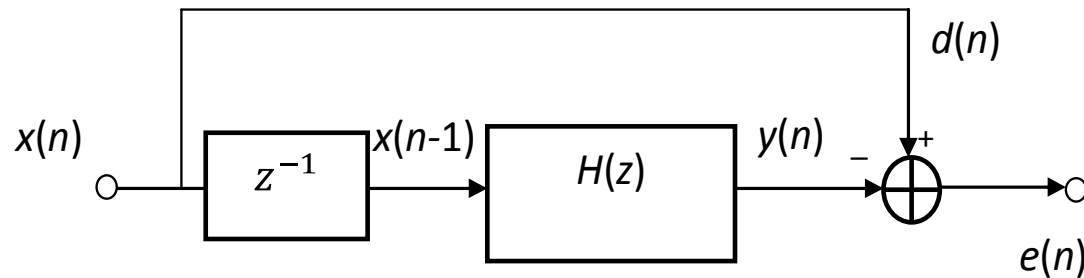
$$E\{y_o(n)e_o^*(n)\} = 0$$

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



4. PREDICȚIA LINIARĂ

4.1 Predicția înainte (directă)



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

Se cunosc N eșantioane 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:

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

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*


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

- *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)

Ecuțiile 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

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

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. PREDICȚIA 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. PREDICȚIA 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

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

4.2. PREDICȚIA ÎNAPOI (INVERSĂ)

Analogii cu problema filtrării optimale:

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

$$\mathbf{w}_o \Rightarrow \mathbf{g}_o$$

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

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

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

4.2. PREDICȚIA ÎNAPOI (INVERSĂ)

Se preiau:

- Ecuația normală

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

- Puterea erorii de predicție

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

- Principiul ortogonalității

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

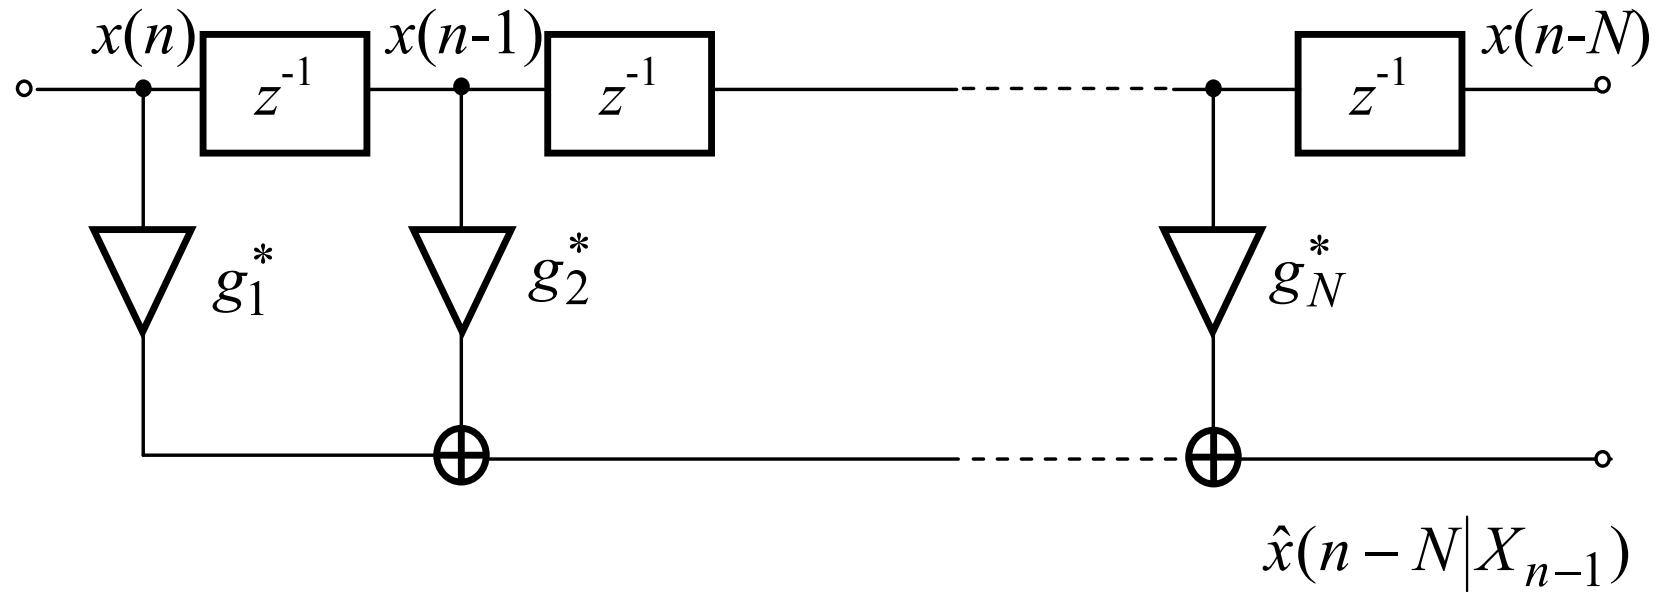
sau

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

4.2. PREDICȚIA 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. PREDICȚIA 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. PREDICȚIA ÎNAPOI (INVERSĂ)

Ecuțiile Wiener-Hopf extinse pentru predicția inversă

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

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

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. PREDICȚIA ÎNAPOI (INVERSĂ)

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

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

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

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

sau

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

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

puterile erorilor de predicție sunt identice în cele două cazuri.

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

Ecuția normală este un sistem $N \times N$

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

Algorithm 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

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

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

4.3.1 Algoritmul Levinson-Durbin

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

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

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

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

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

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 $m = 1 : 1 : N$

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

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

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

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

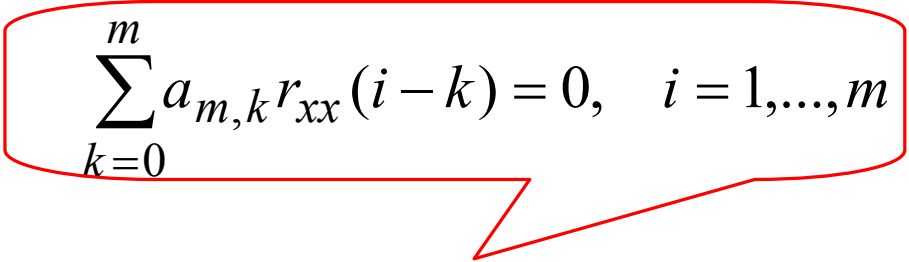
Elementele matricei de autocorelație sunt

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

4.3.2 Algoritmul Schur –

definirea funcțiilor de tip ‘ f ’

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


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

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

4.3.2 Algoritmul Schur – definirea funcțiilor de tip ‘f’

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

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

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

se obțin niște relații de recurență asemănătoare pentru aceste funcții:

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

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

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

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

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

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

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

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

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

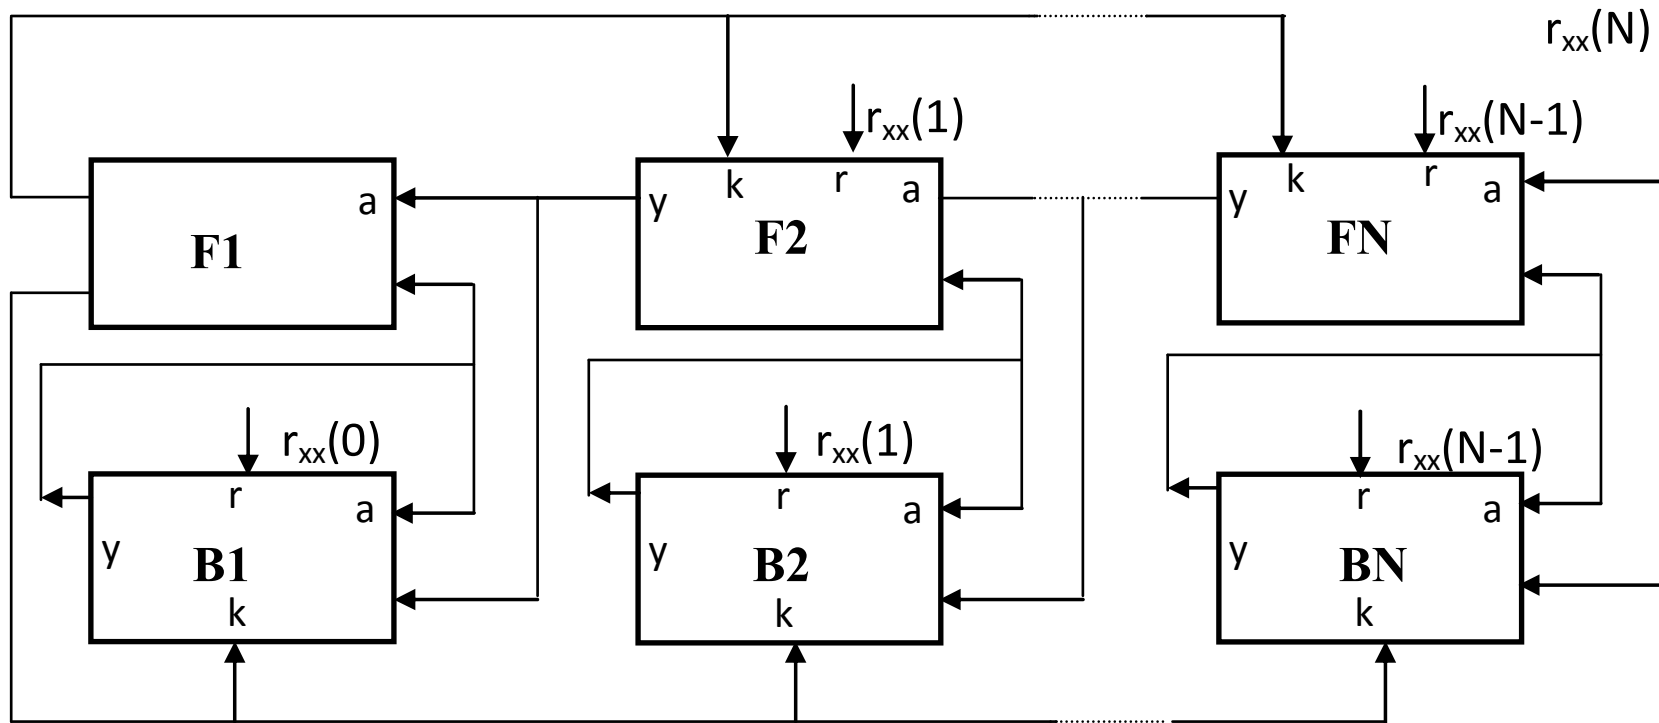
În continuare se repetă ultimele trei operații, deci în pasul m :

- 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

$F_2, \dots, F_N, B_1, \dots, B_N$

F_1



a.



b.

4.4 FILTRELE ERORII DE PREDICȚIE

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.

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

4.4 FILTRELE ERORII DE PREDICȚIE

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 PREDICȚIE

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:

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

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 PREDICȚIE

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 PREDICȚIE

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

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

având în vedere proprietatea 1, rezultă

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

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 PREDICȚIE

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

Relații de recurență pentru eroarea de predicție

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

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

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

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

4.4 FILTRELE ERORII DE PREDICȚIE

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 PREDICȚIE

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



4.4 FILTRELE ERORII DE PREDICȚIE



$e_0^f(n) = e_0^b(n) = x(n)$ - intrarea filtrului

4.4 FILTRELE ERORII DE PREDICȚIE

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 PREDICȚIE

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 așa mai departe până la $N=1$.

4.4 FILTRELE ERORII DE PREDICȚIE

```
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 PREDICȚIE

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 așa 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 pornește 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 PREDICȚIE

```
 $a_{1,1} = k_1, \quad a_{1,0} = 1$   
for  $i = 2:1:N$   
   $a_{i,i} = k_i, \quad a_{i,0} = 1$   
  for  $j = 1:1:i-1$   
     $a_{i,j} = a_{i-1,j} + k_i a_{i-1,i-j}^*$   
  end  
end  
for  $j = 0:1:N$   
   $a_j = a_{N,j}$   
end
```

4.4 FILTRELE ERORII DE PREDICȚIE

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.