

## 5. FILTRE ADAPTIVE BAZATE PE MINIMIZAREA ERORII MEDII PATRATICE

Teoria filtrării optimale oferă soluția găsirii unui filtru optim, în sensul obținerii unei erori medii pătratice minime, în condițiile unui mediu staționar (semnalul de intrare și cel dorit sunt presupuse staționare cel puțin în sens larg). Dacă aceste condiții nu sunt îndeplinite, ar trebui, teoretic, să reevaluăm aplicarea ecuației normale, la fiecare moment de timp. Dar nici această variantă nu este valabilă, pentru că ecuația normală necesită cunoașterea matricei de autocorelație  $\mathbf{R}$  și a vectorului intercorelațiilor  $\mathbf{p}$ . Acestea conțin însă funcții de corelație, deci medii statistice, a căror estimare este o problemă dificilă chiar și în cazul unui mediu staționar. În fine, în cazul unui filtru adaptiv capabil să opereze în timp real, prezintă importanță complexitatea aritmetică, iar aceasta este relativ ridicată în cazul unor filtre de lungime mare.

### 5.1 Metoda pantei descendente maxime (SD- Steepest Descent)

Vom renunța la ideea găsirii coeficienților optimi

$$\mathbf{w}(n) = [w_0(n), w_1(n), \dots, w_{N-1}(n)]$$

într-un singur pas, folosind ecuația normală, și vom adopta o soluție iterativă, prin care să ne apropiem cu un mic pas de soluția optimă în fiecare iterație. Pentru aceasta vom porni de la următoarea

Teoremă

O funcție  $f(\mathbf{z}, \mathbf{z}^*): \mathbb{C}^{2N} \rightarrow \mathbb{R}$  are direcția de variație (creștere) maximă în punctul  $(\mathbf{z}, \mathbf{z}^*)$  dată de gradientul complex  $\nabla_{\mathbf{z}^*} \{f(\mathbf{z}, \mathbf{z}^*)\}$ .

Ca urmare, vom urmări în fiecare iterație ajustarea coeficienților cu un mic pas, în sensul reducerii maxime a funcției cost, urmând etapele de mai jos:

1. - Se pornește de la o valoare inițială a coeficienților  $\mathbf{w}(0)$  (uzual  $\mathbf{w}(0) = \mathbf{0}$ ).
2. - Se evaluează direcția pantei maxime de creștere în jurul acestui punct pe suprafața  $J(\mathbf{w})$ . Aceasta este exprimată prin gradientul complex  $\nabla_{\mathbf{w}^*} (J(\mathbf{w}))$ .
3. - Se reactualizează coeficienții printr-o deplasare pe direcția pantei descendente maxime. Aceasta este echivalent cu o deplasare pe direcția opusă gradientului cu un pas  $\mu$ ,  $\mu \in \mathbf{R}_+$ :

$$\mathbf{w}(n+1) = \mathbf{w}(n) - \mu \nabla_{\mathbf{w}^*} (J(\mathbf{w}))$$

4. - Se reia procedeul din punctul 2.

După cum s-a văzut,

$$\nabla_{\mathbf{w}^*} (J(n)) = -\mathbf{p} + \mathbf{R}\mathbf{w}(n)$$

deci ecuația de reactualizare a coeficienților este

$$\mathbf{w}(n+1) = \mathbf{w}(n) + \mu(\mathbf{p} - \mathbf{R}\mathbf{w}(n))$$

Având în vedere relațiile

$$\mathbf{p} = E\{\mathbf{x}(n)d^*(n)\}, \quad \mathbf{R}\mathbf{w}(n) = E\{\mathbf{x}(n)\mathbf{x}^H(n)\mathbf{w}(n)\}, \quad e(n) = d(n) - \mathbf{w}^H(n)\mathbf{x}(n),$$

Relația de reactualizare mai poate fi scrisă

$$\mathbf{w}(n+1) = \mathbf{w}(n) + \mu E\{\mathbf{x}(n)e^*(n)\}$$

### ***Analiza convergenței algoritmului.***

Fiind un algoritm recursiv, se impune o analiză a convergenței, în sensul de a vedea în ce măsură, atunci când  $n \rightarrow \infty$ , soluția astfel obținută se apropie de aceea dată de filtrul optim. Vom aborda problema convergenței din două puncte de vedere

- *Analiza convergenței coeficienților* către coeficienții optimi, deci măsura în care  $\mathbf{w}(n) \rightarrow \mathbf{w}_o$  când  $n \rightarrow \infty$ .
- *Analiza convergenței funcției cost*, deci măsura în care eroarea medie pătratică tinde către  $J_{\min}$  când  $n \rightarrow \infty$ .

$$\mathbf{Q}^H \mathbf{c}(n+1) = (\mathbf{I} - \mu \mathbf{\Lambda}) \mathbf{Q}^H \mathbf{c}(n)$$

#### **a. Analiza convergenței coeficienților**

Vom introduce **vectorul eroare a coeficienților**, în raport cu valoarea optimă, dată de teoria filtrării optimale,

$$\mathbf{c}(n) = \mathbf{w}(n) - \mathbf{w}_o, \quad \mathbf{R}\mathbf{w}_o = \mathbf{p}$$

Înlocuind în ecuația de reactualizare,

$$\mathbf{c}(n+1) = (\mathbf{I} - \mu \mathbf{R}) \mathbf{c}(n)$$

$$\mathbf{c}(n+1) = (\mathbf{I} - \mu \mathbf{Q} \mathbf{\Lambda} \mathbf{Q}^H) \mathbf{c}(n)$$

Vom introduce de asemenea **vectorul eroare rotit**,

$$\mathbf{v}(n) = \mathbf{Q}^H \mathbf{c}(n) = \mathbf{Q}^H (\mathbf{w}(n) - \mathbf{w}_o)$$

Înmulțind la stânga cu  $\mathbf{Q}^H$  ecuația recursivă obținută mai sus pentru vectorul eroare,

$$\mathbf{v}(n+1) = (\mathbf{I} - \mu \mathbf{\Lambda}) \mathbf{v}(n)$$

Obținem o ecuație cu diferențe finite pentru acest vector, cu condițiile inițiale:

$$\mathbf{v}(0) = \mathbf{Q}^H (\mathbf{w}(0) - \mathbf{w}_o)$$

Ecuația cu diferențe finite poate fi exprimată în formă scalară, având în vedere caracterul de matrice diagonală al expresiei  $(\mathbf{I} - \mu \mathbf{\Lambda})$ , prin setul de relații

$$v_k(n+1) = (1 - \mu \lambda_k) v_k(n), \quad k = 1, 2, \dots, N$$

cu soluția

$$v_k(n) = (1 - \mu\lambda_k)^n v_k(0)$$

Convergența algoritmului impune ca  $v_k(n)$  să tindă la 0 când  $n \rightarrow \infty$ . Pentru aceasta este necesar și suficient ca rația progresiei geometrice respective să fie de modul subunitar:

$$|1 - \mu\lambda_k| < 1 \quad \text{sau} \quad 0 < \mu < \frac{2}{\lambda_k}, \quad k = 1, 2, \dots, N$$


evident îndeplinită dacă și numai dacă

$$0 < \mu < \frac{2}{\lambda_{\max}}$$

După cum s-a văzut, o caracteristică importantă a unui filtru adaptiv este viteza de convergență, ceea ce în cazul de față reprezintă viteza cu care  $v_k(n)$  tinde către zero, sau cu care  $\mathbf{w}_k(n) \rightarrow \mathbf{w}_{o,k}$ ,  $k = 1, \dots, N$ .

După cum s-a văzut,  $\lambda_k \in \mathbf{R}_+$  așa încât  $v_k(n)$  va descrește către 0 fără oscilații. Distingem cazurile:

a)  $0 < \mu\lambda_k < 1$  sau  $0 < \mu < \frac{1}{\lambda_k}$ , iar rația progresiei,  $0 < 1 - \mu\lambda_k < 1$  așa încât  $v_k(n)$  descreșc uniform (figura a).



**Figura 5.1.** Evoluția erorii coeficienților, în cazurile a și b.

Se poate defini o constantă de timp, scriind

$$v_k(n) = (1 - \mu\lambda_k)^n v_k(0) = e^{-n/\tau_k} v_k(0),$$

De unde, logaritmând,

$$\tau_k = -\frac{1}{\ln(1 - \mu\lambda_k)}.$$

Evident, cu cât constanta de timp este mai mică, cu atât convergența este mai rapidă. Acest lucru se întâmplă dacă  $\mu$  se apropie de valoarea limită,  $\mu \approx \frac{1}{\lambda_k}$ . Din contra, o valoare foarte mică a pasului la implica o convergență lentă.

b)  $-1 < 1 - \mu\lambda_k < 0$  sau  $\frac{1}{\lambda_k} < \mu < \frac{2}{\lambda_k}$  -  $v_k(n)$  va fi reprezentat de un șir alternat, având în vedere că rația este negativă (figura b),

$$v_k(n) = e^{-n/\tau_k} (-1)^n v_k(0), \quad \tau_k = -\frac{1}{\ln(\mu\lambda_k - 1)}$$

Și în acest caz, viteza maximă se obține pentru  $\mu \approx \frac{1}{\lambda_k}$ , scăzând către limita superioară a intervalului.

c)  $1 - \mu\lambda_k = 0 \Rightarrow v_k(n) = 0, \quad n \geq 1$  - este o situație limită, ce ar putea fi îndeplinită doar pentru o valoare a lui  $k$ .

Dintre cele trei cazuri prezentate mai sus, importanță practică prezintă cazul a, care presupune alegerea pasului conform relației  $0 < \mu < \frac{1}{\lambda_{Max}}$ . Cazul b nu conduce la avantaje privind viteza de convergență, dar prezintă un grad de risc, ca urmare a apropierii de pragul de convergență.

Relațiile obținute mai sus pot fi exprimate într-o formă unitară,

$$v_k(n) = e^{-n/\tau_k} s_k^n v_k(0), \quad \tau_k = -\frac{1}{\ln|1 - \mu\lambda_k|}, \quad s_k = \text{sgn}(1 - \mu\lambda_k)$$

Coeficienții  $w_k(n)$  se pot exprima sub forma

$$\mathbf{w}(n) = \mathbf{w}_o + \mathbf{Q}\mathbf{v}(n) = \mathbf{w}_o + \sum_{k=1}^N \mathbf{q}_k v_k(n)$$

$$w_i(n) = w_{oi} + \sum_{k=1}^N (q_{ik} v_k(0) (1 - \mu\lambda_k)^n) = w_{oi} + \sum_{k=1}^N (q_{ik} v_k(0) s_k^n e^{-n/\tau_k})$$

Aceste formule conduc la următoarele concluzii

- Convergența coeficienților are loc după o sumă ponderată de exponențiale.
- Se obține viteza de convergență maximă atunci când  $q_{ik} v_k(0)$  sunt nuli, pentru toți  $k$ , exceptând valoarea corespunzătoare lui  $\lambda_{Max}$ .
- Dacă nu sunt precizate condițiile inițiale, în cazul cel mai defavorabil, viteza de convergență este determinată de  $\lambda_{min}$ , pentru care se obține constanta de timp maximă. Ca urmare a celor arătate mai sus, să presupunem o alegere a pasului de forma

$$\mu = r \frac{1}{\lambda_{max}}, \quad 0 < r < 1$$

$$w_i(n) = w_{oi} + \sum_{k=1}^N \left( q_{ik} v_k(0) \left( 1 - r \frac{\lambda_k}{\lambda_{\max}} \right)^n \right)$$

Termenul cel mai lent descrescător este acela care conține factorul

$$\left( 1 - r \frac{\lambda_{\min}}{\lambda_{\max}} \right)^n$$

Acesta scade cu atât mai lent cu cât raportul  $\lambda_{\max}/\lambda_{\min}$  este mai mare, ceea ce se întâmplă dacă matricea  $\mathbf{R}$  este rău condiționată.

### Analiza convergenței funcției cost

$$J(n) = E \left\{ e(n)^2 \right\}$$

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

$$J(n) = E \left\{ \left( e_o(n) - \mathbf{c}^H(n) \mathbf{x}(n) \right) \left( e_o^*(n) - \mathbf{x}^H(n) \mathbf{c}(n) \right) \right\} = E \left\{ e_o(n) e_o^*(n) \right\} - \\ - E \left\{ e_o(n) \mathbf{x}^H(n) \mathbf{c}(n) \right\} - E \left\{ \mathbf{c}^H(n) \mathbf{x}(n) e_o^*(n) \right\} + E \left\{ \mathbf{c}^H(n) \mathbf{x}(n) \mathbf{x}^H(n) \mathbf{c}(n) \right\}$$

Având în vedere că  $\mathbf{c}(n)$  este determinist, iar  $e_o$  satisface principiul ortogonalității,

$$J(n) = J_{\min} + \mathbf{c}^H(n) \mathbf{R} \mathbf{c}(n)$$

sau

$$J(n) = J_{\min} + \mathbf{c}^H(n) \mathbf{Q} \mathbf{\Lambda} \mathbf{Q}^H \mathbf{c}(n) = J_{\min} + \mathbf{v}^H(n) \mathbf{\Lambda} \mathbf{v}(n)$$


sau scalar:

$$J(n) = J_{\min} + \sum_{k=1}^N \lambda_k |v_k(n)|^2 = J_{\min} + \sum_{k=1}^N \lambda_k (1 - \mu \lambda_k)^{2n} |v_k(0)|^2 = \\ = J_{\min} + \sum_{k=1}^N \lambda_k e^{-2n/\tau_k} |v_k(0)|^2$$

Curba obținută reprezentând  $J(n)$  este numită *curba de învățare* a algoritmului. Se constată că indiferent de condițiile inițiale  $v_k(0)$ , eroarea medie pătratică tinde către  $J_{\min}$  dacă este îndeplinită condiția de convergență.

De exemplu, pentru

$$N = 2 \quad \Rightarrow \quad J(n) - J_{\min} = \lambda_1 v_1^2(n) + \lambda_2 v_2^2(n)$$



**Figura 5.2** Aspectul funcției cost(stânga) și a unor secțiuni cu plane de  $J=\text{const}$

Intersecțiile cu plane  $J=\text{const}$  sunt elipse cu semiaxele (Figura 5.2)

$$a = \left( \frac{J(n) - J_{\min}}{\lambda_1} \right)^{1/2}, \quad b = \left( \frac{J(n) - J_{\min}}{\lambda_2} \right)^{1/2}$$

## 5.2 Algoritmul gradientului stohastic

În cazul metodei SD ajustarea coeficienților se face pe baza gradientului erorii medii pătratice:

$$\nabla(J(n)) = -\mathbf{p} + \mathbf{R}\mathbf{w}(n); \quad \mathbf{R} = E\{\mathbf{x}(n)\mathbf{x}^H(n)\}; \quad \mathbf{p} = E\{\mathbf{x}(n)d^*(n)\}$$

Mediile statistice în general nu sunt însă cunoscute. Se recurge la o estimare a gradientului utilizând niște valori estimate pentru cele două matrice renunțând la operațiile de mediere statistică:

$$\hat{\mathbf{R}}(n) = \mathbf{x}(n)\mathbf{x}^H(n); \quad \hat{\mathbf{p}}(n) = \mathbf{x}(n)d^*(n)$$

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

$$\begin{aligned} \mathbf{w}(n+1) &= \mathbf{w}(n) + \mu \mathbf{x}(n) \left( d^*(n) - \mathbf{x}^H(n)\mathbf{w}(n) \right) \\ \mathbf{w}(n+1) &= \mathbf{w}(n) + \mu \mathbf{x}(n) e^*(n) \end{aligned}$$




Figura 5.3. Reprezentare sub forma de graf a algoritmului LMS

$$\begin{aligned}
 & \mathbf{w}(0) = \mathbf{0} \\
 & \text{for } n = 0, 1, 2, \dots \\
 & \quad y(n) = \mathbf{w}^H(n) \mathbf{x}(n) \\
 & \quad e(n) = d(n) - y(n) \\
 & \quad \mathbf{w}(n+1) = \mathbf{w}(n) + \mu \mathbf{x}(n) e^*(n) \\
 & \text{end}
 \end{aligned}$$

### Observații

- Complexitate aritmetică:  $2N+1$  înmulțiri și  $2N$  adunări pentru fiecare iterație
- Având în vedere criteriul de optimizare, se întâlnește în limba engleză sub denumirea *Least Mean Square* (LMS).
- Fiind calculat de fiecare dată utilizând setul de eșantioane  $\mathbf{x}[n]$ , ce au un caracter aleator, fără a efectua o mediere, gradientul estimat va avea de asemenea un caracter aleator.
- Înmulțirile cu  $\mathbf{x}[n]$  din schema algoritmului dau acestuia un caracter neliniar.

### Analiza convergenței

În principiu, vom aborda problema convergenței algoritmului din aceleași două puncte de vedere, convergența coeficienților și convergența funcției de transfer, ca și în cazul algoritmului SD. Intervine însă o diferență esențială. În cazul SD gradientul ce permitea reactualizarea coeficienților avea un caracter determinist, fiind media statistică a unor mărimi presupuse staționare. În cazul LMS, după cum s-a arătat, ca urmare a renunțării la mediere, gradientul va avea un caracter

stochastic și la fel și coeficienții estimați la un moment dat și erorile acestora. Cu reformulările de rigoare, cele două abordări devin

- Convergența în medie a coeficienților. Va trebui testat în ce măsură tinde valoarea medie a vectorului  $\mathbf{w}(n)$  către  $\mathbf{w}_o$  atunci când  $n \rightarrow \infty$ . În caz afirmativ, se zice că algoritmul este *convergent în medie*.

- Convergența funcției cost. Va trebui testat în ce măsură tinde  $J(n)$  către o valoare finită atunci când  $n \rightarrow \infty$ ? În caz afirmativ se spune că algoritmul este *convergent în medie pătratică*.

Caracterul aleatoriu a mărimilor ce intră în discuție, face ca analiza să fie foarte dificilă într-un caz foarte general, fără a face unele ipoteze asupra mărimilor de intrare. Un set uzual de ipoteze e cunoscut în literatură sub denumirea de

*Ipoteze de independență:*

- $\mathbf{x}(1), \mathbf{x}(2), \dots, \mathbf{x}(n)$  sunt statistic independenți.
- $d(n)$  este statistic independent față de  $d(1), \dots, d(n-1)$  și față de  $x(1), x(2), \dots, x(n-1)$ .
- vectorul de intrare  $\mathbf{x}(n)$  și  $d(n)$  formează împreună un set de variabile aleatoare gaussiene.

Desigur, aceste ipoteze sunt discutabile, dar ele ușurează analiza, iar rezultatele obținute sunt în general verificate în practică. În plus, pentru analiza convergenței vom presupune procesele aleatoare  $\mathbf{x}(n)$  și  $d(n)$  staționare și de medie nulă. Ultima dintre ipoteze, asociată cu aceea de medie nulă pentru semnalele de intrare implică echivalența dintre noțiunile de ortogonalitate, necorelare și independență statistică. Pornind de la aceste ipoteze și de la relațiile de reactualizare a coeficienților,

$$\mathbf{w}(n) = \mathbf{w}(n-1) + \mu \mathbf{x}(n-1) e^*(n-1)$$

rezultă

$$E\{\mathbf{w}^H(n) \mathbf{x}(n)\} = 0 \text{ și } E\{\mathbf{c}^H(n) \mathbf{x}(n)\} = 0$$

deci independența vectorului eroare a coeficienților față de vectorul intrării la orice  $n$ .

Datorită lipsei medierii în calculul gradientului apare un *zgomot de gradient*,  $\mathbf{N}(n)$ ,

$$\hat{\nabla}(J(n)) = \nabla(J(n)) + \mathbf{N}(n)$$

$$\mathbf{N}(n) = \hat{\nabla}(J(n)) - E\{\hat{\nabla}(J(n))\} = -(\mathbf{x}(n)e^*(n) - E\{\mathbf{x}(n)e^*(n)\})$$

Evident, este un vector de valoare medie nulă.

$$E\{\mathbf{N}(n)\} = \mathbf{0}$$

*Analiza convergenței în medie a coeficienților*

Relația de reactualizare a coeficienților devine

$$\mathbf{w}(n+1) = \mathbf{w}(n) - \mu(\nabla J(n) + \mathbf{N}(n)) = \mathbf{w}(n) + \mu(\mathbf{p} - \mathbf{R}\mathbf{w}(n)) - \mu\mathbf{N}(n)$$

sau, introducând vectorul eroare,



$$\mathbf{w}_o + \mathbf{c}(n+1) = \mathbf{w}_o + \mathbf{c}(n) + \mu(\mathbf{p} - \mathbf{R}\mathbf{w}_o - \mathbf{R}\mathbf{c}(n)) - \frac{1}{2}\mu\mathbf{N}(n)$$

$$\mathbf{c}(n+1) = (\mathbf{I} - \mu\mathbf{R})\mathbf{c}(n) - \frac{1}{2}\mu\mathbf{N}(n)$$

Înmulțind la stânga cu  $\mathbf{Q}^H$ ,


$$\mathbf{v}(n+1) = (\mathbf{I} - \mu\mathbf{\Lambda})\mathbf{v}(n) - \frac{1}{2}\mu\mathbf{Q}^H\mathbf{N}(n)$$

$$E\{\mathbf{v}(n+1)\} = (\mathbf{I} - \mu\mathbf{\Lambda})E\{\mathbf{v}(n)\}$$

Având în vedere analogia formală dintre această ecuație și cea corespunzătoare în cazul algoritmului SD, concluziile trase acolo pentru vectorul eroare a coeficienților  $\mathbf{v}(n)$  se pot transpune aici pentru media acestui vector,  $E\{\mathbf{v}(n)\}$ . Algoritmul LMS este deci **convergent în medie** dacă:

$$0 < \mu < \frac{2}{\lambda_{\max}}$$

Observație. Trebuie însă reținută diferența esențială între convergența coeficienților în cazul SD și LMS. În cazul SD, era o scădere monotonă a erorii coeficienților, după o sumă de exponențiale, în timp ce în cazul LMS, media media acestei erori are această proprietate, în timp ce eroarea instantanee variază aleatoriu în jurul acestei medii (figura 5.4).



**Figura 5.4** Comparare între convergența coeficienților în algoritmul SD (curba monotonă) și în algoritmul LMS

*Analiza convergenței funcției cost ( în medie pătratică )*

După cum s-a văzut în cazul SD, funcția cost poate fi scrisă

$$J(n) = J_{\min} + E\{\mathbf{c}^H(n)\mathbf{x}(n)\mathbf{x}^H(n)\mathbf{c}(n)\}$$

Dar,

$$\begin{aligned} E\{\mathbf{c}^H(n)\mathbf{x}(n)\mathbf{x}^H(n)\mathbf{c}(n)\} &= E\{\text{tr}\{\mathbf{x}(n)\mathbf{x}^H(n)\mathbf{c}(n)\mathbf{c}^H(n)\}\} = \\ &= \text{tr}\{E\{\mathbf{x}(n)\mathbf{x}^H(n)\}E\{\mathbf{c}(n)\mathbf{c}^H(n)\}\} = \text{tr}\{\mathbf{R}\mathbf{C}(n)\} \end{aligned}$$

unde

$$\mathbf{C}(n) = E\{\mathbf{c}(n)\mathbf{c}^H(n)\}$$

În deducerea relației de mai sus s-au avut în vedere următoarele considerente

Fie doi vectori  $\mathbf{u} = [u_1, \dots, u_N]^T$ ,  $\mathbf{v} = [v_1, \dots, v_N]^T$ , atunci,

$$\mathbf{v}^H \mathbf{u} = \text{tr}\{\mathbf{u}\mathbf{v}^H\} = \sum_{i=1}^N u_i v_i^*$$

egalitate ce se aplică pentru  $\mathbf{v}^H = \mathbf{c}^H(n)$ ,  $\mathbf{u} = \mathbf{x}(n)\mathbf{x}^H(n)\mathbf{c}(n)$ .

$$J(n) = J_{\min} + \text{tr}\{\mathbf{R}\mathbf{C}(n)\} = J_{\min} + J_{ex}(n)$$

unde  $J_{ex}(n)$  reprezintă o *eroare în exces* în raport cu filtrul optimal.

$$J(n) = J_{\min} + \text{tr}\{\mathbf{Q}\mathbf{\Lambda}\mathbf{Q}^H\mathbf{C}(n)\} = J_{\min} + \text{tr}\{\mathbf{\Lambda}\mathbf{Q}^H\mathbf{C}(n)\mathbf{Q}\} = J_{\min} + \text{tr}\{\mathbf{\Lambda}\mathbf{K}(n)\}$$

unde

$$\mathbf{K}(n) = E\{\mathbf{v}(n)\mathbf{v}^H(n)\} = \mathbf{Q}^H\mathbf{C}(n)\mathbf{Q}$$

$$J_{ex}(n) = \sum_{i=1}^N \lambda_i k_{ii}(n)$$

În raport cu filtrul optimal, apare deci o eroare medie pătratică suplimentară, sau în exces, notată cu  $J_{ex}$ , ce poate fi pusă pe seama zgomotului de gradient. Pentru evaluarea sa sunt necesari termenii de pe diagonala principală a matricei  $\mathbf{K}(n)$ .

$$J_{ex}(n) = J_{ex}(\infty) + J_{tr}(n)$$

$$J_{ex}(\infty) = J_{\min} \frac{\sum_{i=1}^N \frac{\mu\lambda_i}{2 - \mu\lambda_i}}{1 - \sum_{i=1}^N \frac{\mu\lambda_i}{2 - \mu\lambda_i}}$$

Se definește *dezadaptarea* (misadjustment) prin

$$M = \frac{J_{ex}(\infty)}{J_{\min}} = \frac{\sum_{i=1}^N \frac{\mu\lambda_i}{2 - \mu\lambda_i}}{1 - \sum_{i=1}^N \frac{\mu\lambda_i}{2 - \mu\lambda_i}}$$

Pentru  $\mu \ll \frac{2}{\lambda_{\max}}$

$$M \cong \frac{\mu}{2} \sum_{i=1}^N \lambda_i = \frac{\mu N}{2} r(0) = \frac{\mu N}{2} \lambda_{\text{med}}, \quad \text{unde} \quad \lambda_{\text{med}} = \frac{1}{N} \sum_{i=1}^N \lambda_i$$

Are în general o tendință de scădere cu micșorarea pasului  $\mu$ , de creștere cu ordinul filtrului  $N$ , și e proporțional cu puterea medie a semnalului de intrare.

Componenta tranzitorie  $J_r(n) \rightarrow 0$  când  $n \rightarrow \infty$  dacă

$$0 < \mu < \frac{2}{\lambda_{\text{max}}} \quad \cap \quad \sum_{i=1}^N \frac{\mu \lambda_i}{2 - \mu \lambda_i} < 1$$

Dacă  $0 < \mu \ll 1$  ambele condiții sunt îndeplinite dacă

$$0 < \mu < \frac{2}{\sum_{j=1}^N \lambda_j}$$

$$\sum_{j=1}^N \lambda_j = Nr(0), \quad r(0) = E\{x^*(n-k)x(n-k)\} = P_x, \quad k = 0, 1, \dots, N-1$$

$P_x$  reprezintă **puterea secvenței**  $x(n)$ , deci o formă simplificată a condiției de convergență este:

$$0 < \mu < \frac{2}{NP_x}; \quad M = \frac{\mu N}{2} P_x$$

Se poate introduce o constantă de timp medie:

$$\tau_{\text{med}} = \frac{1}{2\mu\lambda_{\text{med}}}$$

care caracterizează viteza de scădere a părții tranzitorii a erorii.

**Se constată că dacă  $\mu$  este mic, constanta de timp e mare, conducând la o adaptare lentă, dar dezadaptarea este mică.**

Curba ce reprezintă funcția cost, deci eroarea pătratică medie, este denumită și **curba de învățare (learning curve)**

### 5.3. Metoda gradientului stohastic normalizat

(Metoda normalizată a minimizării erorii medii pătratice - NLMS)

Poate fi privită ca o problemă de optimizare cu constrângeri. Ne propunem să determinăm noile valori  $\mathbf{w}(n+1)$  ale coeficienților astfel încât să se minimizeze norma euclidiană a variației:

$$\delta\mathbf{w}(n+1) = \mathbf{w}(n+1) - \mathbf{w}(n)$$

cu condiția ca:

$$\mathbf{w}^H(n+1)\mathbf{x}(n) = d(n) \quad (1)$$

deci noii coeficienți să aibă acele valori care, cu un tact mai înainte, ar fi anulat eroarea. Vom constitui **funcția cost** reală:

$$J(n) = \|\delta\mathbf{w}(n+1)\|^2 + \text{Re}\{\lambda[\mathbf{w}^H(n+1)\mathbf{x}(n) - d(n)]\}$$

care își atinge minimul odată cu  $\|\delta\mathbf{w}(n+1)\|$  dacă este îndeplinită condiția (1)

$$\begin{aligned} J(n) &= (\mathbf{w}^H(n+1) - \mathbf{w}^H(n))(\mathbf{w}(n+1) - \mathbf{w}(n)) + \\ &+ \frac{1}{2}[\lambda(\mathbf{w}^H(n+1)\mathbf{x}(n) - d(n)) + \lambda^*(\mathbf{x}^H(n)\mathbf{w}(n+1) - d^*(n))] = \\ &= \mathbf{w}^H(n+1)\mathbf{w}(n+1) - \mathbf{w}^H(n+1)\mathbf{w}(n) - \mathbf{w}^H(n)\mathbf{w}(n+1) + \mathbf{w}^H(n)\mathbf{w}(n) + \\ &+ \frac{1}{2}(\lambda\mathbf{w}^H(n+1)\mathbf{x}(n) + \lambda^*\mathbf{x}^H(n)\mathbf{w}(n+1)) - \frac{1}{2}(\lambda d(n) + \lambda^*d^*(n)) \end{aligned}$$

Pentru a găsi vectorul  $\mathbf{w}(n+1)$  ce minimizează această expresie vom aplica metoda gradientului complex.

$$\begin{aligned} \nabla(\mathbf{w}^H(n+1)\mathbf{w}(n+1)) &= 2\mathbf{w}(n+1) \\ \nabla(\mathbf{w}^H(n+1)\mathbf{w}(n) + \mathbf{w}^H(n)\mathbf{w}(n+1)) &= 2\mathbf{w}(n) \\ \nabla(\lambda\mathbf{w}^H(n+1)\mathbf{x}(n) + \lambda^*\mathbf{x}^H(n)\mathbf{w}(n+1)) &= 2\lambda\mathbf{x}(n) \end{aligned}$$

Rezultă:

$$\mathbf{w}(n+1) - \mathbf{w}(n) = -\frac{1}{2}\lambda\mathbf{x}(n)$$

$\lambda$  se obține punând condiția (1). Pentru aceasta se înmulțește la stânga ultima relație cu  $\mathbf{x}^H(n)$ :

$$\begin{aligned} \mathbf{x}^H(n)\mathbf{w}(n+1) - \mathbf{x}^H(n)\mathbf{w}(n) &= -\frac{1}{2}\lambda\mathbf{x}^H(n)\mathbf{x}(n) = -\frac{1}{2}\lambda\|\mathbf{x}(n)\|^2 \\ \lambda &= -\frac{2}{\|\mathbf{x}(n)\|^2}(d^*(n) - \mathbf{x}^H(n)\mathbf{w}(n)) = -\frac{2}{\|\mathbf{x}(n)\|^2}e^*(n) \end{aligned}$$

Noii coeficienți se vor calcula deci cu formula:

$$\mathbf{w}(n+1) = \mathbf{w}(n) + \frac{1}{\|\mathbf{x}(n)\|^2}\mathbf{x}(n)e^*(n)$$

Se obișnuiește să se introducă o scalare a pasului cu o constantă  $\bar{\mu}$ , deci:

$$\mathbf{w}(n+1) = \mathbf{w}(n) + \frac{\bar{\mu}}{\|\mathbf{x}(n)\|^2} \mathbf{x}(n)e^*(n)$$

Poate fi echivalat cu algoritmul gradientului stohastic pentru:

$$\mu(n) = \frac{\bar{\mu}}{\|\mathbf{x}(n)\|^2}$$

în care pasul este variabil.

Deoarece putem aproxima, în cazul unor filtre de lungime mare

$$\|\mathbf{x}(n)\|^2 \cong N\sigma_x^2 = NP_x$$

Condiția de convergență dedusă pentru LMS conduce la:

$$0 < \bar{\mu} < 2$$

Evită prin normare *amplificarea zgomotului gradientului*, în expresia coeficienților  $\mathbf{w}(n+1)$ .

Apar în plus un număr de  $N$  înmulțiri și  $N-1$  adunări la calculul fiecărui coeficient, ca urmare a necesității evaluării lui  $\|\mathbf{x}(n)\|^2$ . Eventual

$$\|\mathbf{x}(n)\|^2 = \sum_{k=0}^{N-1} |x(n-k)|^2 = \|\mathbf{x}(n-1)\|^2 + |x(n)|^2 - |x(n-N)|^2$$

Pentru a elimina riscul unei eventuale împărțiri prin zero (absență a semnalului pe o durată de cel puțin  $N$  tacte), formula de reactualizare utilizată este

$$\mathbf{w}(n+1) = \mathbf{w}(n) + \frac{\bar{\mu}}{\delta + \|\mathbf{x}(n)\|^2} \mathbf{x}(n)e^*(n); \quad \delta > 0$$

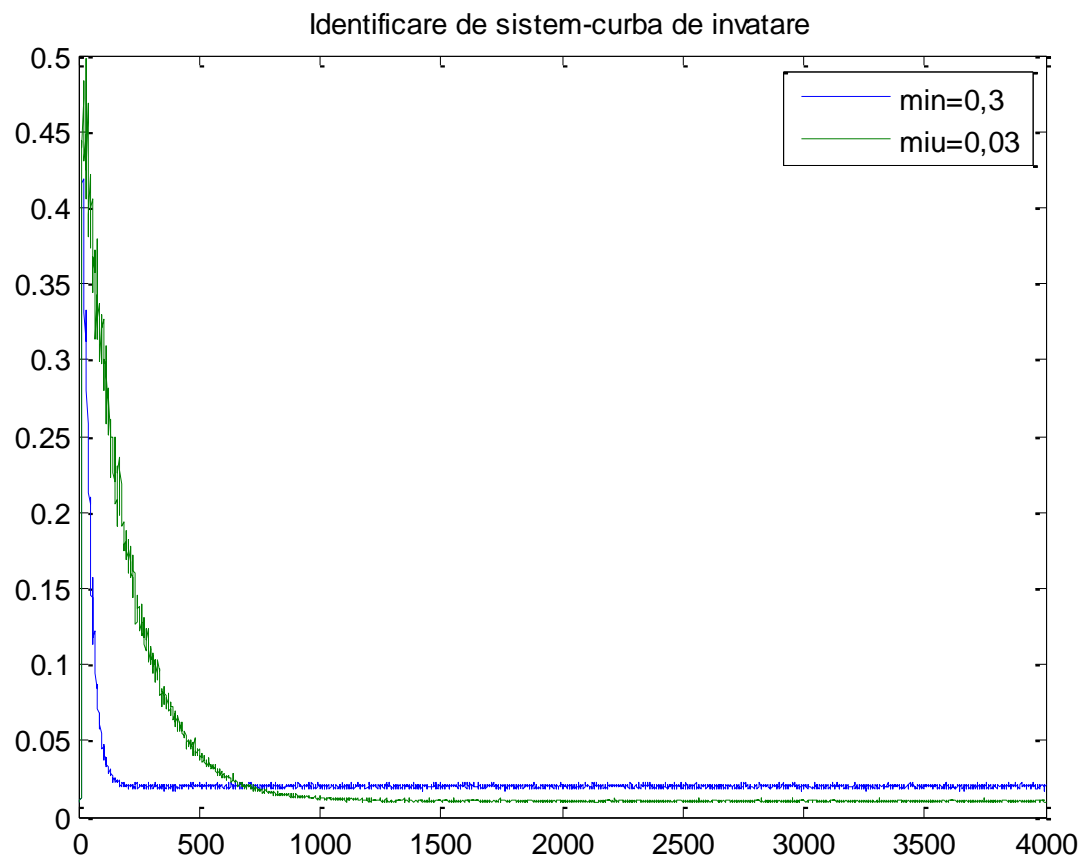
în care s-a introdus *factorul de regularizare*  $\delta$ . Dacă acesta este privit doar ca o măsură de a elimina riscul împărțirii prin zero, el poate avea o valoare pozitivă mică, astfel încât să nu afecteze viteza de convergență.

*Observații.*

- Această variantă a algoritmului LMS este mai mult folosită decât cea originală, în primul rând pentru că nu necesită o estimare apriori a puterii semnalului de intrare pentru a putea alege valoarea pasului  $\mu$ .
- Există în acest caz două grade de libertate în configurarea algoritmului, reprezentate prin parametrii  $\mu$  și  $\delta$ . Ei au în principiu acțiuni contrare, având în vedere ca pasul echivalent este  $\mu(n) = \frac{\bar{\mu}}{\delta + \|\mathbf{x}(n)\|^2}$ . Valori mari pentru  $\bar{\mu}$ , apropiate de valoarea 1, conduc la o convergență rapidă, dar și la o

dezadaptare redusă. Efectul lui  $\delta$  este invers. O alegere corectă presupune un compromis rezonabil între cele două criterii.

- Apare atunci ideea unui algoritm cu pas  $\bar{\mu}$  variabil. Într-adevăr, la pornirea algoritmului, ar fi util un  $\bar{\mu}$  mare pentru a avea o convergență rapidă. O situație simnilară apare când se produce o schimbare bruscă a mediului. După intrarea în convergență, valoarea lui  $\bar{\mu}$  poate fi redusă, urmărind reducerea erorii în exces.
- O abordare alternativă are în vedere optimizarea regularizării.



**Figura 5.5** Evoluția funcției cost pentru două valori ale pasului


- O problemă caracteristică a algoritmilor de tip SD și a celor derivați din acesta, este convergența lentă în cazul unor semnale rău condiționate, deci a unor semnale de intrare puternic corelate.

## 5.4 Metoda gradientului pentru structuri latice (GAL – Gradient adaptive lattice)

Algoritmii LMS/NLMS prezentați până aici presupuneau o realizare a filtrului adaptiv cu răspuns finit la impuls în formă transversală. În această secțiune se vor prezenta algoritmii de funcționare mai întâi pentru un predictor în forma latice, iar apoi, pentru un filtru adaptiv.

### 5.4.1 Predictor adaptiv în structura latice

Datorită structurii modulare, problema se rezolvă separat, pentru fiecare celulă în parte. Vom considera deci o celulă,  $m$  din structura filtrului erorii de predicție (figura 5.6), pentru care singurul parametru ce trebuie reglat este coeficientul de reflexie  $k_m$ . Deoarece filtrul furnizează ambele erori de predicție, în constituirea funcției cost se poate porni de la eroarea de predicție directă, inversă, sau compusă (o formă care să le includă pe amândouă). În cele ce urmează ne vom propune să determinăm  $k_m$  așa încât să fie minimizată eroarea medie pătratică de predicție, în forma compusă,



**Figura 5.6** Celula latice

$$J_m(n) = E\left\{|e_m^f(n)|^2 + |e_m^b(n)|^2\right\}$$

#### Abordarea SD-GAL

Conform metodei gradientului, va trebui luat  $k_m(n+1)$ ,

$$k_m(n+1) = k_m(n) - \mu_m \nabla_m(J_m(n))$$

unde s-a notat simplificat  $\nabla_m(J_m(n)) = \nabla_{k_m^*}(J_m(n))$  gradientul complex (derivata) în raport cu  $k_m^*(n)$ :

$$\begin{aligned} \nabla_m(J_m(n)) = & E\left\{\nabla_m\left(e_m^{f*}(n)\right)e_m^f(n) + e_m^{f*}(n)\nabla_m\left(e_m^f(n)\right)\right\} + \\ & + E\left\{\nabla_m\left(e_m^{b*}(n)\right)e_m^b(n) + e_m^{b*}(n)\nabla_m\left(e_m^b(n)\right)\right\} \end{aligned}$$

Folosind relațiile de recurență:

$$\begin{aligned} e_m^f(n) &= e_{m-1}^f(n) + k_m e_{m-1}^b(n-1) \\ e_m^b(n) &= k_m^* e_{m-1}^f(n) + e_{m-1}^b(n-1) \\ k_m &= k_m^r + j k_m^i \end{aligned} \quad (2)$$

$$\nabla_m(e_m^{f*}(n)) = \frac{1}{2} \left( \frac{\partial}{\partial k_m^r} + j \frac{\partial}{\partial k_m^i} \right) (k_m^r - j k_m^i) e_{m-1}^{b*}(n-1) = e_{m-1}^{b*}(n-1)$$

$$\nabla_m(e_m^f(n)) = \frac{1}{2} \left( \frac{\partial}{\partial k_m^r} + j \frac{\partial}{\partial k_m^i} \right) (k_m^r + j k_m^i) e_{m-1}^b(n-1) = 0$$

$$\nabla_m(e_m^b(n)) = \frac{1}{2} \left( \frac{\partial}{\partial k_m^r} + j \frac{\partial}{\partial k_m^i} \right) (k_m^r - j k_m^i) e_{m-1}^f(n) = e_{m-1}^f(n)$$

$$\nabla_m(e_m^{b*}(n)) = \frac{1}{2} \left( \frac{\partial}{\partial k_m^r} + j \frac{\partial}{\partial k_m^i} \right) (k_m^r + j k_m^i) e_{m-1}^{f*}(n) = 0$$

deci expresia gradientului este

$$\nabla_m(J(n)) = E\{e_m^f(n)e_{m-1}^{b*}(n-1) + e_m^{b*}(n)e_{m-1}^f(n)\}$$

Rezultă:

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

sau utilizând relațiile de recurență (2)

$$k_m(n+1) = k_m(n) \left[ 1 - \mu_m E\{|e_{m-1}^b(n-1)|^2 + |e_{m-1}^f(n)|^2\} \right] - 2\mu_m E\{e_{m-1}^f(n)e_{m-1}^{b*}(n-1)\}$$

Condiția de stabilitate este:

$$\left| 1 - \mu_m E\{|e_{m-1}^b(n-1)|^2 + |e_{m-1}^f(n)|^2\} \right| < 1$$

Deci

$$0 < \mu_m < \frac{2}{E\{|e_{m-1}^b(n-1)|^2 + |e_{m-1}^f(n)|^2\}}$$

### **Abordarea LMS-GAL**

Cum însă mediile statistice nu sunt în general cunoscute, se preferă de obicei utilizarea *gradientului stochastic*, renunțând la operațiile de mediere:

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

Se poate utiliza un algoritm normalizat, normând incrementul la energia erorii de predicție compusă, corespunzătoare intrărilor celulei m:

$$\mu_m = \mu_m(n) = \frac{1}{W_{m-1}(n)}$$

$$\begin{aligned} W_{m-1}(n) &= \sum_{i=1}^n \left[ |e_{m-1}^f(i)|^2 + |e_{m-1}^b(i-1)|^2 \right] = \\ &= W_{m-1}(n-1) + |e_{m-1}^f(n)|^2 + |e_{m-1}^b(n-1)|^2 \end{aligned}$$



Uneori se introduce un parametru  $0 < \beta < 1$ , care permite alocarea unor ponderi diferite pentru eșantioanele precedente și cele actuale:

$$W_{m-1}(n) = \beta W_{m-1}(n-1) + (1-\beta) \left( |e_{m-1}^f(n)|^2 + |e_{m-1}^b(n-1)|^2 \right)$$

În general se obține o convergență mai rapidă utilizând structuri latice decât structuri transversale.

Suprafețele  $J(n)$  sunt pătratice în coeficienții de reflexie, având un minim, dar secțiunile cu  $J = \text{const.}$  nu mai sunt în general elipse. Trebuie remarcat că fiecare coeficient  $k_m$  se evaluează independent urmărind minimizarea lui  $J_m(n)$ .

#### 5.4.1 Filtre adaptive în structura latice

Algoritmul precedent permitea obținerea unui predictor. Pentru a realiza un filtru adaptiv care să estimeze un semnal dorit, structura latice a predictorului se completează cu o structură în scară (figura 5.7).

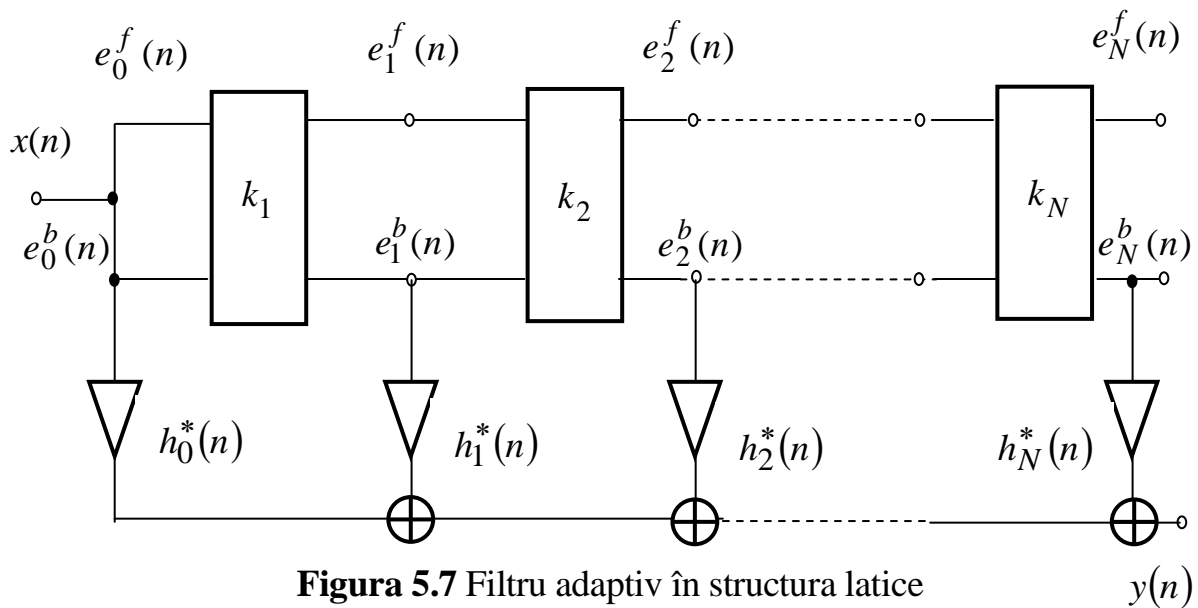


Figura 5.7 Filtru adaptiv în structura latice

În partea superioară a schemei se observă un predictor lattice, al cărui rol este de a furniza semnale decorelate  $e_i^b(n)$ ,  $i = 0, \dots, N$  pentru structura în scară. Structura în scară efectuează o însumare ponderată a acestora, cu ponderile  $h_i^*(n)$ ,  $i = 0, \dots, N$  astfel reglate încât ieșirea să estimeze cât mai corect un semnal dorit  $d(n)$ . Cu notațiile

$$\mathbf{h}(n) = (h_0(n), h_1(n), \dots, h_N(n))^T$$

$$\mathbf{e}_N^b(n) = (e_0^b(n), e_1^b(n), \dots, e_N^b(n))^T$$

eroarea poate fi exprimată prin

$$e(n) = d(n) - y(n) = d(n) - \mathbf{h}^H(n) \mathbf{e}_N^b(n)$$

Coefficienții  $k_i$  se calculează cu algoritmul GAL, iar  $h_i$  din condiția minimizării funcției cost

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

Conform ecuației Wiener-Hopf, coeficienții optimi sunt dați de

$$\mathbf{R}_e \mathbf{h}_o = \mathbf{r}_{ed}$$

unde

$$\mathbf{R}_e = E\{\mathbf{e}_N^b(n) \mathbf{e}_N^{bH}(n)\}; \quad \mathbf{r}_{ed} = E\{\mathbf{e}_N^b(n) d^*(n)\}$$

În cazul coeficienților  $k_i$  optimi, ieșirile lăței sunt ortogonale,

$$E\{e_r^b(n) e_l^{b*}(n)\} = \begin{cases} 0, & r \neq l \\ E\{|e_r^b(n)|^2\} = P_r, & r = l \end{cases}$$

*Demonstrație*

$$e_r^b(n) = \sum_{k=0}^r c_{r,k} x(n-k)$$

deci

$$E\{e_r^b(n) e_l^{b*}(n)\} = E\left\{\sum_{k=0}^r c_{r,k} x(n-k) e_l^{b*}(n)\right\} = \sum_{k=0}^r c_{r,k} E\{x(n-k) e_l^{b*}(n)\}$$

Dar, conform ortogonalității

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

Rezultă că

$$E\{e_r^b(n) e_l^{b*}(n)\} = 0 \text{ pentru } r < l.$$

În mod asemănător, exprimând

$$e_l^b(n) = \sum_{k=0}^l c_{l,k} x(n-k)$$

se deduce egalitatea cu 0 pentru  $l < r$ . Rezultă că

$$\mathbf{R}_e = \text{diag}\{P_0, P_1, \dots, P_N\}$$

$$h_{o,k} = \frac{1}{P_k} E\{e_k^b(n) d^*(n)\}$$

Pentru un algoritm recursiv, recurgem la metoda gradientului. În varianta SD:

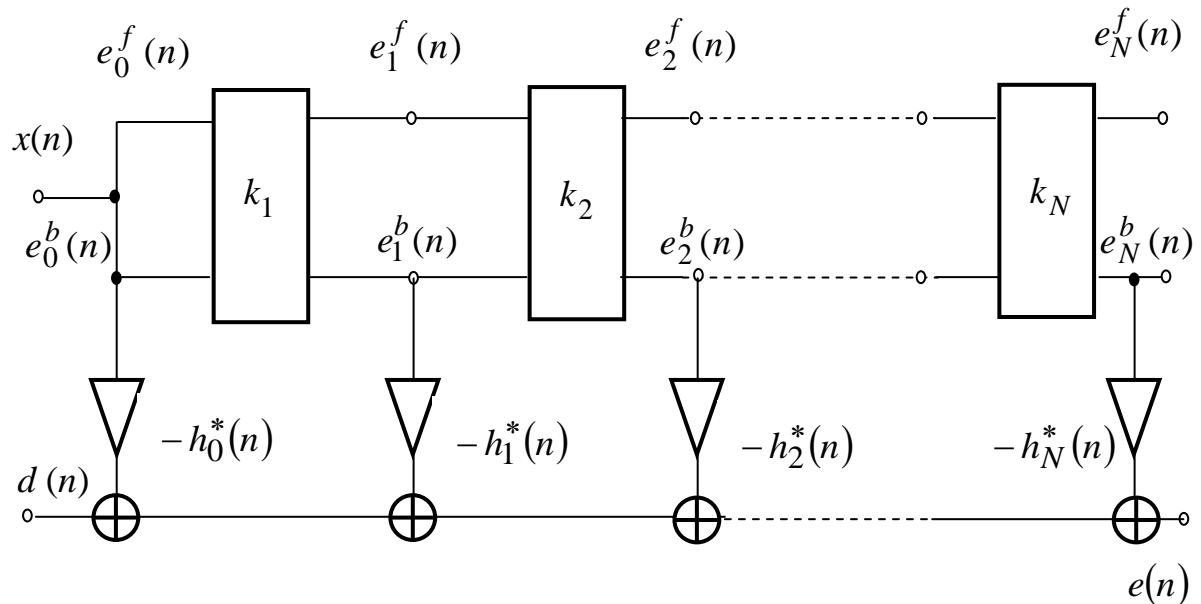
$$\begin{aligned} \mathbf{h}(n+1) &= \mathbf{h}(n) - \mu \nabla_{\mathbf{h}^*} J(n) \\ \nabla_{\mathbf{h}^*} (J(n)) &= -\mathbf{r}_{ed} + \mathbf{R}_e \mathbf{h}(n) = \\ &= -E\{\mathbf{e}_N^b(n) d^*(n)\} + E\{\mathbf{e}_N^b(n) \mathbf{e}_N^{bH}(n)\} \mathbf{h}(n) \end{aligned}$$

Cum valorile medii nu sunt în general cunoscute, aplicăm metoda gradientului stohastic (LMS),

$$\hat{\nabla}_{\mathbf{h}^*} (J(n)) = -\mathbf{e}_N^b(n) d^*(n) + \mathbf{e}_N^b(n) \mathbf{e}_N^{bH}(n) \mathbf{h}(n) = -\mathbf{e}_N^b(n) e^*(n)$$

rezultând ecuația de reactulizare a ponderilor

$$\mathbf{h}(n+1) = \mathbf{h}(n) + \mu e^*(n) \mathbf{e}_N^b(n)$$



**Figura 5.8** Filtru adaptiv în structura latice, care generează eroarea de estimare

Avantajul principal al acestor algoritmi este acela că datorită operației de decorelare efectuată de structura latice, convergența mai rapidă, în cazul unor date de intrare puternic corelate.

În figura 5.8 este dată o variantă de schemă care generează eroarea de estimare.

