

7. FILTRE ADAPTIVE BAZATE PE METODA CELOR MAI MICI PĂTRATE

7.1 Metoda recursivă a celor mai mici pătrate (RLS)

7.1 Metoda recursivă a celor mai mici pătrate

(RLS)

7.1.1 Algoritmul RLS

Funcția cost: eroare pătratică ponderată

$$J(n) = \sum_{i=1}^n \beta(n,i) |e(i)|^2$$

în care

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

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

Factorul de pondere

$$\beta(n,i) = \lambda^{n-i}, \quad i = 1, \dots, n, \quad 0 < \lambda \leq 1$$

$$J(n) = \sum_{i=1}^n \lambda^{n-i} |e(i)|^2$$

7.1 Metoda recursivă a celor mai mici pătrate (RLS)

7.1.1 Algoritmul RLS

$$J(n) = \sum_{i=1}^n \lambda^{n-i} (d(i) - \mathbf{w}^H(n) \mathbf{x}(i)) (d^*(i) - \mathbf{x}^H(i) \mathbf{w}(n))$$

$$J(n) = \sum_{i=1}^n \lambda^{n-i} |d(i)|^2 - \mathbf{w}^H(n) \sum_{i=1}^n \lambda^{n-i} \mathbf{x}(i) d^*(i) - \\ - \sum_{i=1}^n \lambda^{n-i} \mathbf{x}^H(i) d(i) \mathbf{w}(n) + \mathbf{w}^H(n) \sum_{i=1}^n \lambda^{n-i} \mathbf{x}(i) \mathbf{x}^H(i) \mathbf{w}(n)$$

Notăm

$$\Phi(n) = \sum_{i=1}^n \lambda^{n-i} \mathbf{x}(i) \mathbf{x}^H(i)$$

$$\theta(n) = \sum_{i=1}^n \lambda^{n-i} \mathbf{x}(i) d^*(i)$$

$$E_d(n) = \sum_{i=1}^n \lambda^{n-i} |d(i)|^2$$

7.1 Metoda recursivă a celor mai mici pătrate (RLS)

7.1.1 Algoritmul RLS

$$\mathbf{\Phi}(n) = \sum_{i=1}^n \lambda^{n-i} \mathbf{x}(i) \mathbf{x}^H(i)$$

$$\boldsymbol{\theta}(n) = \sum_{i=1}^n \lambda^{n-i} \mathbf{x}(i) d^*(i)$$

$$E_d(n) = \sum_{i=1}^n \lambda^{n-i} |d(i)|^2$$

$\mathbf{\Phi}(n)$, $\boldsymbol{\theta}(n)$, $E_d(n)$ reprezintă estimatori deplasati ai matricei de autocorelație, vectorului corelației între semnalul dorit și secvența de intrare și respectiv puterii semnalului dorit.

$$J(n) = E_d - \mathbf{w}^H(n) \boldsymbol{\theta}(n) - \boldsymbol{\theta}^H(n) \mathbf{w}(n) + \mathbf{w}^H(n) \mathbf{\Phi}(n) \mathbf{w}(n)$$

Anulând gradientul funcției cost se obține ecuația normală.

7.1 Metoda recursivă a celor mai mici pătrate (RLS)

7.1.1 Algoritmul RLS

Ecuatia normală. Minimizarea funcției cost se obține tot pentru

$$\mathbf{\Phi}(n)\mathbf{w}(n) = \mathbf{\theta}(n)$$

Presupunând problema rezolvată pentru $n-1$, deci cunoscând:

$$\mathbf{w}(n-1) = \mathbf{\Phi}^{-1}(n-1)\mathbf{\theta}(n-1)$$

ne propunem să găsim o metodă pentru a evalua

$$\mathbf{w}(n) = \mathbf{\Phi}^{-1}(n)\mathbf{\theta}(n)$$

7.1 Metoda recursivă a celor mai mici pătrate (RLS)

7.1.1 Algoritmul RLS

Relații de recurență pentru $\Phi(n)$ și $\theta(n)$:

$$\Phi(n) = \lambda \sum_{i=1}^{n-1} \lambda^{n-1-i} \mathbf{x}(i) \mathbf{x}^H(i) + \mathbf{x}(n) \mathbf{x}^H(n)$$

$$\Phi(n) = \lambda \Phi(n-1) + \mathbf{x}(n) \mathbf{x}^H(n)$$

$$\theta(n) = \lambda \sum_{i=1}^{n-1} \lambda^{n-1-i} \mathbf{x}(i) d^*(i) + \mathbf{x}(n) d^*(n)$$

$$\theta(n) = \lambda \theta(n-1) + \mathbf{x}(n) d^*(n)$$

7.1 Metoda recursivă a celor mai mici pătrate (RLS)

7.1.1 Algoritmul RLS

Este necesară o metodă de exprimare a inversei matricii $\Phi(n)$, pornind de la relația de recurență.

Lema inversării matricii: Fiind date matricele $\mathbf{A}(N \times N)$, $\mathbf{B}(N \times N)$, $\mathbf{C}(N \times L)$, $\mathbf{D}(L \times L)$, în care \mathbf{A} , \mathbf{B} , \mathbf{D} , sunt nesingulare și satisfac relația:

$$\mathbf{A} = \mathbf{B} + \mathbf{C}\mathbf{D}\mathbf{C}^H$$

inversa matricii \mathbf{A} este dată de

$$\mathbf{A}^{-1} = \mathbf{B}^{-1} - \mathbf{B}^{-1}\mathbf{C}\left(\mathbf{D}^{-1} + \mathbf{C}^H\mathbf{B}^{-1}\mathbf{C}\right)^{-1}\mathbf{C}^H\mathbf{B}^{-1}$$

Vom aplica această leamnă pentru:

$$\mathbf{A} = \Phi(n), \quad \mathbf{B} = \lambda\Phi(n-1), \quad \mathbf{C} = \mathbf{x}(n), \quad \mathbf{D} = \mathbf{I} = 1$$

$$\Phi^{-1}(n) = \lambda^{-1}\Phi^{-1}(n-1) -$$

$$- \lambda^{-1}\Phi^{-1}(n-1)\mathbf{x}(n)\left(1 + \mathbf{x}^H(n)\lambda^{-1}\Phi^{-1}(n-1)\mathbf{x}(n)\right)^{-1}\mathbf{x}^H(n)\lambda^{-1}\Phi^{-1}(n-1)$$

7.1 Metoda recursivă a celor mai mici pătrate (RLS)

7.1.1 Algoritmul RLS

$$\begin{aligned} \mathbf{\Phi}^{-1}(n) = & \lambda^{-1} \mathbf{\Phi}^{-1}(n-1) - \\ & - \lambda^{-1} \mathbf{\Phi}^{-1}(n-1) \mathbf{x}(n) \left(1 + \mathbf{x}^H(n) \lambda^{-1} \mathbf{\Phi}^{-1}(n-1) \mathbf{x}(n) \right)^{-1} \mathbf{x}^H(n) \lambda^{-1} \mathbf{\Phi}^{-1}(n-1) \end{aligned}$$

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

$$\begin{aligned} \mathbf{P}(n) & \triangleq \mathbf{\Phi}^{-1}(n); \\ \mathbf{k}(n) & \triangleq \frac{1}{\lambda} \frac{\mathbf{P}(n-1) \mathbf{x}(n)}{1 + \frac{1}{\lambda} \mathbf{x}^H(n) \mathbf{P}(n-1) \mathbf{x}(n)} \end{aligned}$$

$$\mathbf{P}(n) = \frac{1}{\lambda} \mathbf{P}(n-1) - \frac{1}{\lambda} \mathbf{k}(n) \mathbf{x}^H(n) \mathbf{P}(n-1)$$

7.1 Metoda recursivă a celor mai mici pătrate (RLS)

7.1.1 Algoritmul RLS

$\mathbf{P}(n)$ este o matrice pătrată $N \times N$;

$\mathbf{k}(n)$ este un vector $N \times 1$, numit *vectorul câștig (Kalman)*.

Ecuția de mai sus este o ecuație de tip *Riccati*.

$$\begin{aligned}\mathbf{k}(n) &= \frac{1}{\lambda} \mathbf{P}(n-1) \mathbf{x}(n) - \frac{1}{\lambda} \mathbf{k}(n) \mathbf{x}^H(n) \mathbf{P}(n-1) \mathbf{x}(n) = \\ &= \left(\frac{1}{\lambda} \mathbf{P}(n-1) - \frac{1}{\lambda} \mathbf{k}(n) \mathbf{x}^H(n) \mathbf{P}(n-1) \right) \mathbf{x}(n)\end{aligned}$$

deci

$$\begin{aligned}\mathbf{k}(n) &= \mathbf{P}(n) \mathbf{x}(n) \\ \mathbf{\Phi}(n) \mathbf{k}(n) &= \mathbf{x}(n)\end{aligned}$$

7.1 Metoda recursivă a celor mai mici pătrate (RLS)

7.1.1 Algoritmul RLS

Avem acum toate elementele pentru exprimarea lui $\mathbf{w}(n)$.

$$\begin{aligned}\mathbf{w}(n) &= \mathbf{\Phi}^{-1}(n)\boldsymbol{\theta}(n) = \mathbf{P}(n)\boldsymbol{\theta}(n) = \lambda\mathbf{P}(n)\boldsymbol{\theta}(n-1) + \mathbf{P}(n)\mathbf{x}(n)d^*(n) \\ \mathbf{w}(n) &= \mathbf{P}(n-1)\boldsymbol{\theta}(n-1) - \mathbf{k}(n)\mathbf{x}^H(n)\mathbf{P}(n-1)\boldsymbol{\theta}(n-1) + \mathbf{P}(n)\mathbf{x}(n)d^*(n) = \\ &= \mathbf{\Phi}^{-1}(n-1)\boldsymbol{\theta}(n-1) - \mathbf{k}(n)\mathbf{x}^H(n)\mathbf{\Phi}^{-1}(n-1)\boldsymbol{\theta}(n-1) + \mathbf{k}(n)d^*(n) \\ \mathbf{w}(n) &= \mathbf{w}(n-1) + \mathbf{k}(n)\left(d^*(n) - \mathbf{x}^H(n)\mathbf{w}(n-1)\right) = \mathbf{w}(n-1) + \mathbf{k}(n)\alpha^*(n)\end{aligned}$$

unde

$$\begin{aligned}\mathbf{w}(n) &= \mathbf{w}(n-1) + \mathbf{k}(n)\alpha^*(n) \\ \alpha(n) &= d(n) - \mathbf{w}^H(n-1)\mathbf{x}(n)\end{aligned}$$

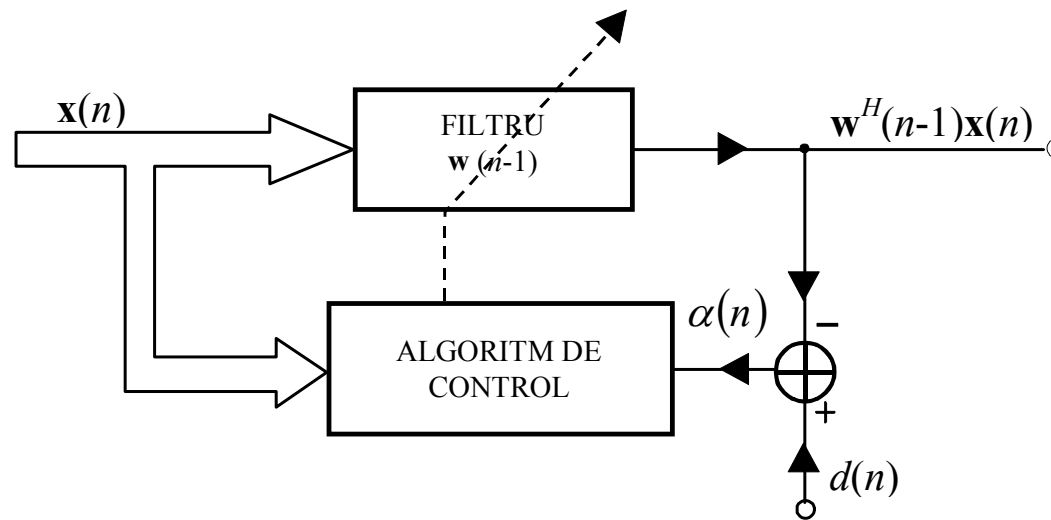
reprezintă eroarea estimării obținute utilizând vechile valori $\mathbf{w}(n-1)$ ale coeficienților pentru noile date, deci *eroarea de estimare apriori*, numită și *inovație*. Ea nu coincide cu eroarea aposteriori

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

7.1 Metoda recursivă a celor mai mici pătrate (RLS)

7.1.1 Algoritmul RLS


$$\mathbf{w}(n) = \mathbf{w}(n-1) + \mathbf{k}(n)\alpha^*(n)$$
$$\alpha(n) = d(n) - \mathbf{w}^H(n-1)\mathbf{x}(n)$$



7.1 Metoda recursivă a celor mai mici pătrate (RLS)

7.1.1 Algoritmul RLS

$$\mathbf{w}(n) = \mathbf{w}(n-1) + \mathbf{k}(n)\alpha^*(n)$$
$$\alpha(n) = d(n) - \mathbf{w}^H(n-1)\mathbf{x}(n)$$



7.1 Metoda recursivă a celor mai mici pătrate (RLS)

7.1.1 Algoritmul RLS

Relațiile de ortogonalitate

$$\sum_{i=1}^n \lambda^{n-i} \mathbf{x}(i) e_{\min}^*(i) = \mathbf{0}$$

$$\sum_{i=1}^n \lambda^{n-i} y_0(i) e_{\min}^*(i) = 0$$

Consecință

$$E_{\min}(n) = J_{\min}(n) = E_d(n) - E_y(n)$$

În cazul de față:

$$\begin{aligned} E_y(n) &= \sum_{i=1}^n \lambda^{n-i} y_0(i) y_0^*(i) = \sum_{i=1}^n \lambda^{n-i} \mathbf{w}^H(n) \mathbf{x}(i) \mathbf{x}^H(i) \mathbf{w}(n) = \\ &= \mathbf{w}^H(n) \Phi(n) \mathbf{w}(n) = \boldsymbol{\theta}^H(n) \mathbf{w}(n) \end{aligned}$$

așa încât rezultă o primă expresie utilă:

$$J_{\min}(n) = E_d(n) - \boldsymbol{\theta}^H(n) \mathbf{w}(n)$$

7.1 Metoda recursivă a celor mai mici pătrate (RLS)

7.1.1 Algoritmul RLS

$$E_d(n) = \sum_{i=1}^n \lambda^{n-i} |d(i)|^2 = \lambda \sum_{i=1}^{n-1} \lambda^{n-1-i} |d(i)|^2 + |d(n)|^2 = \lambda E_d(n-1) + |d(n)|^2$$

Ținând seama și de relațiile de recurență pentru $\boldsymbol{\theta}(n)$ și $\mathbf{w}(n)$, rezultă

$$\begin{aligned} J_{\min}(n) &= \lambda E_d(n-1) + |d(n)|^2 - \left(\lambda \boldsymbol{\theta}^H(n-1) + d(n) \mathbf{x}^H(n) \right) \left(\mathbf{w}(n-1) + \mathbf{k}(n) \alpha^*(n) \right) = \\ &= \lambda \left(E_d(n-1) - \boldsymbol{\theta}^H(n-1) \mathbf{w}(n-1) \right) + \\ &+ d(n) \left(d^*(n) - \mathbf{x}^H(n) \mathbf{w}(n-1) \right) - \left(\lambda \boldsymbol{\theta}^H(n-1) + d(n) \mathbf{x}^H(n) \right) \mathbf{k}(n) \alpha^*(n) = \\ &= \lambda J_{\min}(n-1) + d(n) \alpha^*(n) - \boldsymbol{\theta}^H(n) \mathbf{k}(n) \alpha^*(n) \end{aligned}$$

Ultimul termen al sumei se mai scrie

$$\boldsymbol{\theta}^H(n) \mathbf{k}(n) \alpha^*(n) = \boldsymbol{\theta}^H(n) \boldsymbol{\Phi}^{-1}(n) \mathbf{x}(n) \alpha^*(n) = \mathbf{w}^H(n) \mathbf{x}(n) \alpha^*(n)$$

Revenind la $J_{\min}(n)$ se obține:

$$J_{\min}(n) = \lambda J_{\min}(n-1) + \alpha^*(n) \left(d(n) - \mathbf{w}^H(n) \mathbf{x}(n) \right)$$

$$J_{\min}(n) = \lambda J_{\min}(n-1) + \alpha^*(n) e(n)$$

7.1 Metoda recursivă a celor mai mici pătrate (RLS)

7.1.1 Algoritmul RLS

Inițializare

$$\mathbf{P}(0) = \delta^{-1} \mathbf{I}, \quad \mathbf{w}(n) = \mathbf{0}$$

for $n=1,2,\dots$

$$\mathbf{z}(n) = \mathbf{x}^H(n) \mathbf{P}(n-1)$$

(N^2 înmulțiri și $N(N-1)$ adunări)

$$\mathbf{k}(n) = \frac{1}{\lambda + \mathbf{z}(n) \mathbf{x}(n)} \mathbf{z}^H(n)$$

($2N$ înmulțiri și N adunări)

$$\alpha(n) = d(n) - \mathbf{w}^H(n-1) \mathbf{x}(n)$$

(N înmulțiri și N adunări)

$$\mathbf{w}(n) = \mathbf{w}(n-1) + \mathbf{k}(n) \alpha^*(n)$$

(N înmulțiri și N adunări)

$$\mathbf{P}(n) = \frac{1}{\lambda} (\mathbf{P}(n-1) - \mathbf{k}(n) \mathbf{z}(n))$$

($2N^2$ înmulțiri și N^2 adunări)

end

7.1 Metoda recursivă a celor mai mici pătrate (RLS)

7.1.1 Algoritmul RLS

Complexitatea aritmetică a algoritmului

Inițializarea algoritmului constă în impunerea valorilor $\mathbf{P}[0]$ și $\mathbf{w}[0]$. Uzual se ia $\mathbf{w}[0]=\mathbf{0}$ și

$$\mathbf{P}(0) = \delta^{-1} \mathbf{I}$$

unde δ este o valoare constantă mică, astfel încât matricea de autocorelație să nu rezulte singulară.

Complexitatea aritmetică este de $3N^2 + 4N$ înmulțiri și $2N^2 + 2N$ adunări, deci numărul de operații este de forma $O(N^2)$, (crește cu N^2).