

# L'EQUALIZZAZIONE AUTOMATICA

---

## 1 – Generalità.

La determinazione del valore dei pesi dell'equalizzatore presenta notevole difficoltà perché non è nota la forma dell'impulso di segnalazione  $q(t)$  in arrivo al ricevitore. Si tenga presente che, nella maggior parte dei casi (come ad esempio nella trasmissione wireless), le caratteristiche del canale variano con il tempo cosicché la risposta  $q(t)$  non può ritenersi costante per tutto il periodo della trasmissione.

Il modo per determinare il valore dei pesi  $c_i$  è basato su un algoritmo iterativo che consiste nell'aggiornare ad ogni istante di lettura  $kT$  (al passo  $k$ ) il valore dei pesi  $c$  ottenuto al passo precedente. Il criterio di aggiornamento dipende dal tipo di equalizzatore ed dal criterio scelto per effettuare l'aggiornamento; nelle seguenti sezioni tali tecniche sono illustrate con riferimento ad equalizzatori di tipo ZF e di tipo MMSE.

In quel che segue si prendono in esame gli equalizzatori conformati utilizzando filtri a risposta impulsiva finita.

## 2 – Equalizzatori ZF.

Il problema della determinazione dei pesi del filtro trasversale è ricondotto (v. par. 8 del Cap. "L'equalizzazione di canale") alla soluzione del sistema  $\mathbf{Q}\mathbf{Q}^H \mathbf{c}_o = \mathbf{Q}\mathbf{u}_D$ .

Nel risolvere un tale sistema si presentano due difficoltà:

- non si conoscono gli elementi della matrice  $\mathbf{Q}$  perché non è nota la forma dell'impulso di segnalazione;
- pur ammettendo di stimare gli elementi della matrice  $\mathbf{Q}$ , la determinazione dei pesi  $\mathbf{c}_o$  comporta la determinazione della matrice  $(\mathbf{Q}\mathbf{Q}^H)^{-1}\mathbf{Q}$  e tale operazione può richiedere, specie se  $N$  è grande, un tempo di calcolo non compatibile con le alte velocità di trasmissione.

I pesi sono aggiornati in modo tale da annullare l'errore

$$(2.1) \quad e_k = y_k - a_{k-D}$$

fra il valore corrente della variabile di decisione e il dato  $a_{k-D}$  dove  $DT$  denota il ritardo di trasmissione. Ricordando l'espressione della variabile di decisione  $y_k = \mathbf{c}^H \cdot \mathbf{Q} \cdot \mathbf{a}_{k-D} + w_k$  si può scrivere:

$$(2.2) \quad y_k = \tilde{\mathbf{q}}^H \cdot \mathbf{a}_{k-D} + w_k = \sum_n a_{k-D-n} \tilde{q}_n^* + w_k$$

dove si è posto  $\tilde{\mathbf{q}} = \mathbf{Q}^H \mathbf{c}$  ed è  $w_k = \mathbf{c}^H \mathbf{n}_k$ . L'errore quindi diventa:

$$(2.3) \quad e_k = \sum_n a_{k-D-n} \tilde{q}_n^* + w_k - a_{k-D}$$

che moltiplicata per  $a_{k-i}^*$  e mediata fornisce:

$$(2.4) \quad E\{e_k a_{k-i}^*\} = \sum_n E\{a_{k-D-n} a_{k-i}^*\} \tilde{q}_n^* + E\{w_k a_{k-i}^*\} - E\{a_{k-D} a_{k-i}^*\}$$

Se la sequenza dati è composta da elementi tali da aversi:

$$(2.5) \quad E \{ a_m a_n^* \} = \begin{cases} \sigma_a^2 & m = n \\ 0 & m \neq n \end{cases}$$

e la sequenza di rumore si suppone indipendente dalla sequenza dati, si ottiene:

$$(2.6) \quad E \{ e_k a_{k-i}^* \} = \sigma_a^2 (\tilde{q}_{i-D}^* - \delta_{i-D}) = \begin{cases} \sigma_a^2 (\tilde{q}_0^* - 1) & i = D \\ \sigma_a^2 \tilde{q}_{i-D}^* & i \neq D \end{cases}$$

Ciò comporta che, se è verificata la condizione di zero forcing data dalla  $\tilde{q}_i = \delta_i$ , si ha:

$$(2.7) \quad E \{ e_k a_{k-i}^* \} = 0$$

Appare pertanto naturale aggiornare i pesi secondo la seguente legge:

$$(2.8) \quad c_i(k+1) = c_i(k) - \alpha E \{ e_k a_{k-i}^* \}$$

dal momento che la condizione di equilibrio raggiunta dai pesi ( $c_i(m) = \text{cost}$ ) comporta il verificarsi della condizione (2.7). La quantità  $\alpha$  è scelta in modo da assicurare un'adeguata velocità di convergenza dell'algoritmo.

Se la sequenza dati si suppone ergodica si può scrivere, con  $K$  sufficientemente elevato:

$$(2.9) \quad \frac{1}{K} \sum_{k=1}^K e_k a_{k-i}^* \cong E \{ e_k a_{k-i}^* \}$$

In tali ipotesi la legge di aggiornamento diviene:

$$(2.10) \quad c_i(k+1) = c_i(k) - \frac{\alpha}{K} \sum_{k=1}^K (y_k - a_k) a_{k-i}^*$$

Per implementare tale algoritmo basta osservare che se la probabilità di errore di rivelazione risulta sufficientemente piccola, i simboli trasmessi  $a_n$  possono essere considerati eguali ai simboli  $\hat{a}_n$  in uscita dal decisore collegato a valle dell'equalizzatore. La precedente può pertanto essere approssimata dal cosiddetto *pseudo errore* per cui la legge di aggiornamento diventa:

$$(2.11) \quad c_i(k+1) = c_i(k) - \frac{\alpha}{K} \sum_{k=1}^K (y_k - \hat{a}_k) \hat{a}_{k-i}^*$$

### 3 - Equalizzatori MMSE.

#### 3.1 - Algoritmo del gradiente.

Ricordando il criterio adottato per gli equalizzatori di tipo MMSE il modo più naturale di aggiornare i pesi è quello che porta a minimizzare il valore quadratico medio dell'errore  $e_k = y_k - a_{k-D}$ . In questo caso una scelta naturale dell'algoritmo è quella del gradiente (o della discesa più ripida).

Ricordando la (9:4) del Cap "Equalizzazione di canale", l'errore quadratico medio è espresso dalla:

$$(3.1) \quad J(c) = c^H R c - c^H p - p^H c + \sigma_a^2$$

dove

- $R$  denota la matrice di autocorrelazione del vettore  $x_k$  ;
- $p$  denota il vettore delle correlazioni mutue tra il vettore  $x_k$  e i dati  $a_{k-D}$  ;
- $\sigma_a^2$  la varianza della sequenza dei dati.

Infatti, essendo la funzione obiettivo che si vuole minimizzare  $J(\mathbf{c}) = E\{|e_k|^2\}$  una funzione quadratica semidefinita positiva delle variabili  $c_i$ , è l'aggiornamento dell'errore al passo  $k$  avviene secondo una direzione opposta a quella del gradiente della funzione  $J(\mathbf{c})$  calcolata in corrispondenza ai valori del vettore  $\mathbf{c}$  al passo precedente. Ciò, in altri termini, equivale a porre la legge di aggiornamento dei pesi nella forma:

$$(3.2) \quad \mathbf{c}(k+1) = \mathbf{c}(k) - \frac{\alpha}{2} \text{grad}\{J[\mathbf{c}(k)]\}$$

dove  $\alpha$  è un'opportuna costante. In questo modo l'aggiornamento dei pesi dell'equalizzatore avviene secondo le linee di maggior pendenza come è schematicamente indicato in Fig. 1.




Fig. 1 - grad(J)

Ricordando l'espressione del gradiente della funzione  $J(\mathbf{c})$ , la legge di aggiornamento diventa:

$$(3.3) \quad \mathbf{c}(k+1) = \mathbf{c}(k) - \alpha [\mathbf{R}\mathbf{c}(k) - \mathbf{p}]$$

Introducendo il vettore errore al passo  $k$  definito dalla:

$$(3.4) \quad \mathbf{w}(k) = \mathbf{c}(k) - \mathbf{c}_o$$

in cui  $\mathbf{c}_o$  rappresenta il vettore dei pesi ottimo definito dalla

$\mathbf{R}\mathbf{c}_o = \mathbf{p}$ , la (3.3) diventa:

$$(3.5) \quad \mathbf{w}(k+1) + \mathbf{c}_o = \mathbf{w}(k) + \mathbf{c}_o - \alpha [\mathbf{R}\mathbf{w}(k) + \mathbf{R}\mathbf{c}_o - \mathbf{p}]$$

che si semplifica nella:

$$(3.6) \quad \mathbf{w}(k+1) = (\mathbf{I} - \alpha\mathbf{R})\mathbf{w}(k)$$

Per determinare le condizioni che garantiscono la convergenza dell'algoritmo e cioè le condizioni per cui l'errore converge a zero, basta ricordare che la matrice  $\mathbf{R}$  può essere posta nella seguente forma (*decomposizione diagonale*):

$$(3.7) \quad \mathbf{R} = \mathbf{U}\mathbf{A}\mathbf{U}^{-1}$$

dove

$$(3.8) \quad \mathbf{A} = \text{diag}(\lambda_{-N}, \dots, \lambda_0, \dots, \lambda_N) = \begin{bmatrix} \lambda_{-N} & 0 & 0 & 0 & 0 \\ \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & \lambda_0 & 0 & 0 \\ \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & 0 & 0 & \lambda_N \end{bmatrix}$$

è una matrice diagonale i cui elementi sono gli autovalori (supposti distinti) della matrice  $\mathbf{R}$  e  $\mathbf{U}$  è la matrice

$$(3.9) \quad \mathbf{U} = [\mathbf{u}_{-N}, \dots, \mathbf{u}_0, \dots, \mathbf{u}_N]$$

composta dagli autovettori normalizzati corrispondenti (v. Appendice A: Decomposizione diagonale della matrice  $\mathbf{R}$ ). Premoltiplicando ambo i membri della (3.6) per  $\mathbf{U}^{-1}$  e tenendo conto della decomposizione (3.7), si ottiene:

$$(3.10) \quad \mathbf{U}^{-1}\mathbf{w}(k+1) = \mathbf{U}^{-1}(\mathbf{I} - \alpha\mathbf{U}\mathbf{A}\mathbf{U}^{-1})\mathbf{w}(k) = \mathbf{U}^{-1}\mathbf{w}(k) - \alpha\mathbf{U}^{-1}\mathbf{U}\mathbf{A}\mathbf{U}^{-1}\mathbf{w}(k) = (\mathbf{I} - \alpha\mathbf{A})\mathbf{U}^{-1}\mathbf{w}(k)$$

che, introducendo la trasformazione di variabili:

$$(3.11) \quad \bar{\mathbf{w}}(k) = \mathbf{U}^{-1}\mathbf{w}(k)$$

assume la forma:

$$(3.12) \quad \bar{\mathbf{w}}(k+1) = (\mathbf{I} - \alpha\mathbf{A})\bar{\mathbf{w}}(k)$$

che costituisce un insieme di  $N + 1$  equazioni disaccoppiate, la generica della quali è:

$$(3.13) \quad \bar{w}_i(k + 1) = (1 - \alpha\lambda_i) \bar{w}_i(k) \quad i \in \{1, N\}$$

Iterando la precedente si ha:


$$(3.14) \quad \bar{w}_i(k) = (1 - \alpha\lambda_i)^k \bar{w}_i(0) \quad i \in \{1, N\}$$

dalla quale si evince che l'errore, al divergere nel numero  $k$  di iterazioni tende a 0 se tutti i coefficienti  $1 - \alpha\lambda_i$  sono contenuti nell'insieme  $\{-1, 1\}$  e cioè quando

$$(3.15) \quad \phi(\alpha) = \max_i |1 - \alpha\lambda_i| < 1$$

e quindi detto  $\lambda_{\max}$  l'autovalore più grande, deve risultare:

$$(3.16) \quad 0 \leq \alpha \leq \frac{2}{\lambda_{\max}}$$



**Fig. 3** - Andamento del rapporto  $\phi(\alpha_{opt})$  in funzione di  $\lambda_{\max} / \lambda_{\min}$ .

$$(3.17) \quad 1 - \alpha_{opt}\lambda_{\min} = \alpha_{opt}\lambda_{\max} - 1$$

e cioè per

$$(3.18) \quad \alpha_{opt} = \frac{2}{\lambda_{\max} + \lambda_{\min}}$$

L'errore pertanto è influenzato dal valore della quantità:

$$(3.19) \quad \phi(\alpha_{opt}) = \frac{\lambda_{\max} - \lambda_{\min}}{\lambda_{\max} + \lambda_{\min}} = \frac{\lambda_{\max} / \lambda_{\min} - 1}{\lambda_{\max} / \lambda_{\min} + 1}$$

che è rappresentato in Fig. 3 al variare di  $\frac{\lambda_{\max}}{\lambda_{\min}}$ .

La trasformazione (3.11) consente inoltre di controllare singolarmente i modi adeguando i valori del parametro  $\alpha$ . In altri termini scrivendo la (3.12) nella forma:

$$(3.20) \quad \bar{w}(k + 1) = (I - \alpha A) \bar{w}(k)$$

dove:


$$(3.21) \quad A = \text{diag}[\alpha_1 \quad \alpha_2 \quad \dots \quad \alpha_N]$$

e ponendo  $\alpha_i = \alpha\lambda_i$ , la (3.20) diventa:

$$(3.22) \quad \bar{w}(k + 1) = (1 - \alpha) \bar{w}(k)$$

Tutti i modi hanno la stessa velocità di decadimento.

Nello studio dell'algoritmo del gradiente si è anche interessati alla convergenza dell'errore quadratico medio. Ricordando l'espressione  $J(c) = J_{\min} + (c - c_o)^H R(c - c_o)$  ottenuta nel Cap.



**Fig. 2** - Determinazione del valore ottimo del coefficiente  $\alpha$

Infine per rendere più rapida la convergenza si deve scegliere il coefficiente  $\alpha$  in modo da rendere minima la quantità  $\phi(\alpha)$  perché in questo modo s'incrementa la velocità di convergenza del termine esponenziale della (3.14) a minor decadimento.

Se  $\lambda_{\min}$  e  $\lambda_{\max}$  denotano il più piccolo ed il più grande degli autovalori della matrice  $R$ , il grafico della funzione  $\phi(\alpha)$  è contenuto tra  $|1 - \alpha\lambda_{\max}|$  e  $|1 - \alpha\lambda_{\min}|$ , come è riportato nella Fig. 2. Si deduce

che il valore ottimo di  $\alpha$  si ottiene per:

“L'equalizzazione di canale”, tenendo conto della posizione (3.4) e della trasformazione (3.11) si ha:

$$(3.23) \quad J[\mathbf{c}(k)] = J_{\min} + \bar{\mathbf{w}}^H(k) \mathbf{U}^{-1} \mathbf{R} \mathbf{U} \bar{\mathbf{w}}(k)$$

dove si è tenuto conto che è  $\mathbf{U}^H = \mathbf{U}^{-1}$ . Ricordando infine la (3.7) la precedente si semplifica nella:

$$(3.24) \quad J[\mathbf{c}(k)] = J_{\min} + \bar{\mathbf{w}}^H(k) \mathbf{A} \bar{\mathbf{w}}(k)$$

e cioè:

$$(3.25) \quad J[\mathbf{c}(k)] = J_{\min} + \sum_{i=1}^N \lambda_i \bar{w}_i(k) \bar{w}_i^*(k)$$

che, tenendo conto della (3.14), diventa:

$$(3.26) \quad J[\mathbf{c}(k)] = J_{\min} + \sum_{i=1}^N \lambda_i (1 - \alpha \lambda_i)^{2k} |\bar{w}_i(0)|^2$$

dalla quale si evince che, se sono soddisfatte le condizioni di convergenza, l'errore quadratico medio converge a zero con una velocità maggiore di quella che compete ai pesi dell'equalizzatore.

### 3.2 – Algoritmo LMS.

È bene osservare che la legge di aggiornamento dei pesi (3.3) comporta la valutazione della matrice  $\mathbf{R}$  e del vettore  $\mathbf{p}$  che comportano conoscenze delle statistiche della sequenza  $\mathbf{x}$  del segnale ricevuto, della sequenza  $\mathbf{a}$  dei dati e di quella  $\mathbf{n}$  del rumore. Poiché, in generale, queste informazioni non sono note al ricevitore si preferisce stimare la matrice  $\mathbf{R}$  e il vettore  $\mathbf{p}$  sulla base dei dati ricevuti. In particolare se si ipotizza che le sequenze coinvolte siano ergodiche i parametri in questione possono essere stimati mediante le medie temporali come segue:

$$(3.27) \quad \hat{\mathbf{R}} \simeq \frac{1}{M} \sum_{n=k-(M-1)}^k \mathbf{x}_n \mathbf{x}_n^H \quad \hat{\mathbf{p}} \simeq \frac{1}{M} \sum_{n=k-(M-1)}^k \mathbf{x}_n a_{k-D}^*$$

valide se  $M$  è sufficientemente elevato.

Un'approssimazione più drastica basata sull'utilizzazione solo del dato corrente è stata introdotta da Widrow e Hoff. Essa consiste nell'usare le stime:

$$(3.28) \quad \hat{\mathbf{R}} \simeq \mathbf{x}_n \mathbf{x}_n^H \quad \hat{\mathbf{p}} \simeq \mathbf{x}_n a_{k-D}^*$$

che danno luogo alla seguente formulazione dell'algoritmo di aggiornamento dei pesi:

$$(3.29) \quad \mathbf{c}(k+1) = \mathbf{c}(k) - \alpha [\mathbf{x}_k \mathbf{x}_k^H \mathbf{c}(k) - \mathbf{x}_k a_{k-D}^*] = \mathbf{c}(k) - \alpha \mathbf{x}_k e^*(k)$$

essendo  $e(k) = \mathbf{c}^H(k) \mathbf{x}_k - a_{k-D}$  l'errore al passo  $k$ .

È bene osservare che un tale algoritmo corrisponde ad utilizzare come funzione obiettivo il valore quadratico dell'errore di stima  $\hat{J}(\mathbf{c}) = |e_k|^2 = |e_k e_k^*|$ . Infatti, ricordando le posizioni introdotte nel Cap. “L'equalizzazione di canale”, è:

$$(3.30) \quad \begin{aligned} \text{grad}\{\hat{J}(\mathbf{c})\} &= \text{grad}\{e_k e_k^*\} = \text{grad}\left[(y_k - a_{k-D})(y_k - a_{k-D})^*\right] = \\ &= \text{grad}\left\{\left(\mathbf{c}^H \mathbf{x}_k - a_{k-D}\right)\left(\mathbf{c}^H \mathbf{x}_k - a_{k-D}\right)^H\right\} = \text{grad}\left\{\left(\mathbf{c}^H \mathbf{x}_k - a_{k-D}\right)\left(\mathbf{x}_k^H \mathbf{c} - a_{k-D}^*\right)^H\right\} = \\ &= \text{grad}\left\{\mathbf{c}^H \mathbf{x}_k \mathbf{x}_k^H \mathbf{c} - \mathbf{c}^H \mathbf{x}_k a_{k-D}^* - \mathbf{x}_k^H \mathbf{c} a_{k-D} + |a_{k-D}|^2\right\} = 2\left(\mathbf{x}_k \mathbf{x}_k^H \mathbf{c} - \mathbf{x}_k a_{k-D}^*\right) = 2\mathbf{x}_k e^*(k) \end{aligned}$$

Per questo motivo tale algoritmo prende il nome di algoritmo a **minimo errore quadratico**

**LMS (Least Minimum Square error).**

Come nel caso dell'algoritmo del gradiente anche in questo caso occorre indagare sulla convergenza dell'algoritmo; ma poiché l'algoritmo opera su variabili aleatorie la convergenza può essere accertata solo se si prende in esame la media statistica. In altre parole l'algoritmo del gradiente stocastico converge se risulta:

$$(3.31) \quad \lim_{k \rightarrow \infty} E \{c(k)\} = c_o$$

dove  $c_o$  rappresenta la soluzione ottima e cioè la soluzione dell'equazione  $Rc_o = p$ .

La valutazione delle medie statistiche del vettore dei pesi non è matematicamente ottenibile. Per comodità di calcolo si è introdotta una particolare ipotesi nota come **ipotesi di indipendenza**. Essa consiste nel supporre che:

- i. il termine  $x_k$  della sequenza  $\{x_k\}$  è a media nulla e statisticamente indipendente da tutti gli altri termini precedenti  $x_n$  ( $n < k$ );
- ii. il termine  $a_k$  della sequenza  $\{a_k\}$  è a media nulla e statisticamente indipendente da tutti gli altri termini precedenti  $a_n$  ( $n < k$ );
- iii. il termine  $x_k$  è statisticamente indipendente da tutti i termini  $a_n$  ( $n < k$ ) precedenti della sequenza  $\{a_k\}$ .

È da tener presente che tale ipotesi in linea di principio non è accettabile. Ad esempio se si confronta il vettore  $x_k$

$$x_k = [x(k) \quad x(k-1) \quad \dots \quad x(k-N+1)]^T$$

con il vettore  $x_{k-1}$

$$x_{k-1} = [x(k-1) \quad x(k-2) \quad \dots \quad x(k-N)]^T$$

si deduce che essi contengono  $N-1$  termini eguali, precisamente quelli compresi fra  $x(k-N+1)$  e  $x(k-1)$ . Cionondimeno tale ipotesi è giustificata dalla circostanza che parecchie simulazioni al calcolatore hanno dimostrato che i risultati dedotti adoperando l'algoritmo LMS sono pressoché identici con quelli ottenuti introducendo l'ipotesi di indipendenza.

Prendendo le medie statistiche della (3.29), si ha:

$$(3.32) \quad E \{c(k+1)\} = E \{c(k)\} - \alpha E \{x_k x_k^H c(k) - x_k a_{k-D}^*\}$$

Il vettore dei pesi  $c(k)$  al passo  $k$  dipende solo dai vettori  $x_n$  con  $n < k$ , per cui a causa dell'ipotesi di indipendenza, sopra enunciata, può ritenersi indipendente da  $x_k$ . La precedente diviene:

$$(3.33) \quad E \{c(k+1)\} = E \{c(k)\} - \alpha E \{x_k x_k^H\} E \{c(k)\} - \alpha E \{x_k a_{k-D}^*\}$$

che, introducendo l'errore istantaneo  $w(k) = c(k) - c_o$ , assume la forma:

$$(3.34) \quad \begin{aligned} E \{w(k+1)\} &= E \{w(k)\} - \alpha E \{x_k x_k^H\} (E \{w(k)\} + c_o) - \alpha E \{x_k a_{k-D}^*\} = \\ &= [I - \alpha E \{x_k x_k^H\}] E \{w(k)\} - \alpha [E \{x_k x_k^H\} c_o - E \{x_k a_{k-D}^*\}] \end{aligned}$$

che, tenendo conto che è  $E \{x_k x_k^H\} c_o - E \{x_k a_{k-D}^*\} = Rc_o - p = 0$  si può porre nella forma:

$$(3.35) \quad E \{w(k+1)\} = (I - \alpha R) E \{w(k)\}$$

Si è così pervenuto ad una equazione alle differenze identica alla (3.6) già incontrata a proposito dell'algoritmo del gradiente. Con considerazioni identiche a quelle esposte a proposi-

to della convergenza dell'algoritmo del gradiente si può concludere che l'algoritmo LMS è convergente se il parametro  $\alpha$  è contenuto nell'intervallo  $\left(0, \frac{2}{\lambda_{\max}}\right)$ .

La convergenza dell'algoritmo comporta che, in media, il vettore dei pesi tende al valore ottimo ma non assicura che tale convergenza avviene con piccole oscillazioni di  $c$  attorno a  $c_o$ . Occorre pertanto completare l'indagine indagando sulla varianza del vettore  $c$ . A tal proposito basta scrivere la (3.29) come segue:

$$(3.36) \quad c(k+1) = c(k) - \frac{\alpha}{2} \text{grad} \{ \hat{J}[c(k)] \}$$

in termini, cioè, del gradiente della stima  $\hat{J}(k)$  della funzione obiettivo calcolata al passo  $k$ . La quantità  $\text{grad} \{ \hat{J}(k) \}$  è una grandezza aleatoria; pertanto riesce conveniente esprimerla

come somma del gradiente della funzione obiettivo

$$(3.37) \quad \text{grad} \{ J[c(k)] \} = 2(\mathbf{R}c(k) - \mathbf{p})$$

e di un termine aleatorio  $2N(k)$ , supposto a media nulla. In altri termini, si pone:

$$(3.38) \quad \text{grad} \{ \hat{J}[c(k)] \} = \text{grad} \{ J[c(k)] \} + 2N(k)$$

L'algoritmo di aggiornamento (3.36) diventa:

$$(3.39) \quad c(k+1) = c(k) - \alpha[\mathbf{R}c(k) - \mathbf{p}] - \alpha N(k)$$

In termini del vettore errore  $w(k)$  si ha:

$$(3.40) \quad w(k+1) = w(k) - \alpha \{ \mathbf{R}[w(k) + c_o] - \mathbf{p} \} - \alpha N(k) = w(k) - \alpha \mathbf{R}w(k) - \alpha[\mathbf{R}c_o - \mathbf{p}] - \alpha N(k)$$

ovvero:

$$(3.41) \quad w(k+1) = (\mathbf{I} - \alpha \mathbf{R}) w(k) - \alpha N(k)$$

La (3.41) consente di calcolare la matrice di correlazione  $\mathbf{R}_w(k)$  del vettore  $w(k)$  al passo  $k$ . Si ha:

$$(3.42) \quad \begin{aligned} \mathbf{R}_w(k+1) &= E \{ w(k+1) w^H(k+1) \} = \\ &= E \left\{ [(\mathbf{I} - \alpha \mathbf{R}) w(k) - \alpha N(k)] [(\mathbf{I} - \alpha \mathbf{R}) w(k) - \alpha N(k)]^H \right\} = \\ &= E \left\{ [(\mathbf{I} - \alpha \mathbf{R}) w(k) - \alpha N(k)] [w^H(k) (\mathbf{I} - \alpha \mathbf{R})^H - \alpha N^H(k)] \right\} = \\ &= E \left\{ (\mathbf{I} - \alpha \mathbf{R}) w(k) w^H(k) (\mathbf{I} - \alpha \mathbf{R})^H \right\} + \\ &\quad - \alpha E \left\{ (\mathbf{I} - \alpha \mathbf{R}) w(k) N^H(k) + N(k) w^H(k) (\mathbf{I} - \alpha \mathbf{R})^H \right\} + \\ &\quad + \alpha^2 E \left\{ N(k) N^H(k) \right\} \end{aligned}$$

Una notevole semplificazione si ottiene quando l'algoritmo si trova in prossimità della fase di regime e cioè quando  $c(k)$  si può identificare con il valore ottimo  $c_o$ . In tali condizioni, dalla (3.38), si deduce:

$$(3.43) \quad \text{grad} \{ \hat{J}[c(k)] \} \cong \text{grad} \{ J(c_o) \} + 2N(k) = 2N(k)$$

essendo  $\text{grad} \{ J(c_o) \} = \mathbf{R}c_o - \mathbf{p} = \mathbf{0}$ . Tenendo infine conto delle (3.30) e (3.38) è:

$$(3.44) \quad N(k) \cong \mathbf{x}_k e_k^*$$

Dalla (3.44) si desume che  $N(k)$  dipende da  $\mathbf{x}_k$  e  $a_{k-D}$ , mentre dalla (3.41) si evince che  $w(k)$  dipende da  $\mathbf{x}_{k-1}$  e  $N(k-1)$ . Sulla base dell'ipotesi di indipendenza si può pertanto concludere che  $w(k)$  e  $N(k)$  sono statisticamente indipendenti, per cui, essendo  $N(k)$  a media nulla si può scrivere:

$$(3.45) \quad E \{ \mathbf{w}(k) \mathbf{N}^H(k) \} = E \{ \mathbf{N}^H(k) \mathbf{w}(k) \} = 0$$

Inoltre, ricordando che, sempre in virtù dell'ipotesi di indipendenza,  $\mathbf{w}(k)$  è indipendente da  $\mathbf{x}_k(k)$  si ha:

$$(3.46) \quad \mathbf{R}_w(k+1) = E \{ (\mathbf{I} - \alpha \mathbf{R}) \} \mathbf{R}_w(k) E \{ (\mathbf{I} - \alpha \mathbf{R}) \} + \alpha^2 E \{ \mathbf{N}(k) \mathbf{N}^H(k) \}$$

essendo manifestamente  $(\mathbf{I} - \alpha \mathbf{R})^H = \mathbf{I} - \alpha \mathbf{R}$  poiché  $\mathbf{R}$  è una matrice hermitiana.

Per valutare la matrice  $E \{ \mathbf{N}(k) \mathbf{N}^H(k) \}$  occorre introdurre un'ulteriore ipotesi che consiste nel supporre che  $\mathbf{x}_k$  sia statisticamente indipendente dall'errore  $e_k$ . Tenendo presente la

(3.44) si ottiene così:

$$(3.47) \quad E \{ \mathbf{N}(k) \mathbf{N}^H(k) \} = E \{ |e_k|^2 \} E \{ \mathbf{x}_k \mathbf{x}_k^H \} = \mathbf{R} J_{\min}$$

dove  $J_{\min} = E \{ |e_k|^2 \} = E \{ |c_o^H \mathbf{x}_k - a_{k-D}|^2 \} = E \{ |a_k|^2 \} - c_o^H \mathbf{R} c_o$ .

La (3.46) allora diventa:

$$(3.48) \quad \mathbf{R}_w(k+1) = (\mathbf{I} - \alpha \mathbf{R}) \mathbf{R}_w(k) (\mathbf{I} - \alpha \mathbf{R}) + \alpha^2 J_{\min} \mathbf{R}$$

che introducendo la trasformazione (3.11), assume la forma:

$$(3.49) \quad \mathbf{U}^{-1} \mathbf{R}_w(k+1) \mathbf{U} = \mathbf{U} (\mathbf{I} - \alpha \mathbf{\Lambda}) \mathbf{R}_{\bar{w}}(k) (\mathbf{I} - \alpha \mathbf{\Lambda}) \mathbf{U}^{-1} + \alpha^2 J_{\min} \mathbf{U} \mathbf{\Lambda} \mathbf{U}^{-1}$$

dove  $\mathbf{R}_{\bar{w}}(k)$  denota la matrice di correlazione del vettore  $\bar{\mathbf{w}}(k)$ . Si ha:

$$(3.50) \quad \mathbf{R}_{\bar{w}}(k+1) = (\mathbf{I} - \alpha \mathbf{\Lambda}) \mathbf{R}_{\bar{w}}(k) (\mathbf{I} - \alpha \mathbf{\Lambda}) + \alpha^2 J_{\min} \mathbf{\Lambda}$$

Poiché si è interessati soltanto alle varianze delle componenti dei vettori  $\bar{\mathbf{w}}(k)$  occorre prendere in considerazione solo gli elementi della diagonale principale della matrice di autocorrelazione  $\mathbf{R}_{\bar{w}}(k)$ . Denotando con  $\gamma_i(k)$  il generico termine della diagonale principale della matrice  $\mathbf{R}_{\bar{w}}(k)$  si ha:

$$(3.51) \quad \gamma_i(k+1) = (1 - \alpha \lambda_i)^2 \gamma_i(k) + \alpha^2 J_{\min} \lambda_i$$

che iterata dà luogo alla:

$$(3.52) \quad \gamma_i(k) = (1 - \alpha \lambda_i)^{2k} \gamma_i(0) + \alpha^2 J_{\min} \lambda_i \sum_{n=0}^{k/2} (1 - \alpha \lambda_i)^{2n}$$

Poiché, per la convergenza in media è richiesta la condizione  $|1 - \alpha \lambda_i| < 1$  si deduce che risulta:

$$(3.53) \quad \lim_{k \rightarrow \infty} \gamma_i(k) = \alpha^2 J_{\min} \lambda_i \frac{1}{1 - (1 - \alpha \lambda_i)^2}$$

È da osservare che poiché la varianza del generico componente del vettore  $\bar{\mathbf{w}}(k)$  converge ad un valore non nullo, il vettore  $\bar{\mathbf{w}}(k)$  continua a fluttuare attorno al suo valore limite  $\bar{\mathbf{w}}_o$ .



## APPENDICE

### PROPIETÀ DI UNA MATRICE HERMITIANA

#### 1 - Se $R$ denota una matrice hermitiana, gli autovalori sono reali.

Infatti se  $u$  è un autovettore corrispondente all'autovalore  $\lambda$  è

$$Ru = \lambda u$$

che premoltiplicata per  $u^H$  fornisce:

$$(1) \quad u^H Ru = \lambda u^H u$$

Prendendo ancora la trasposta coniugata, si ottiene:

$$(u^H Ru)^H = \lambda^* (u^H u)^H$$

e cioè

$$(2) \quad u^H Ru = \lambda^* u^H u$$

dove si è tenuto conto che è  $R^H = R$ . Dalle (1) e (2) è facile dedurre:

$$(3) \quad \lambda = \lambda^*$$

e cioè l'autovalore  $\lambda$  è reale.

#### 2 - Gli autovettori di una matrice hermitiana sono ortogonali.

Infatti siano  $u_i$  e  $u_j$  due autovettori corrispondenti agli autovalori  $\lambda_i$  e  $\lambda_j$ , supposti distinti. Si ha:

$$(4) \quad Ru_i = \lambda_i u_i \quad \text{e} \quad Ru_j = \lambda_j u_j$$

Premoltiplicando la prima delle (a) per  $u_j^H$  e la seconda per  $u_i^H$ , si ha:

$$(5) \quad u_j^H Ru_i = \lambda_i u_j^H u_i \quad \text{e} \quad u_i^H Ru_j = \lambda_j u_i^H u_j$$

Prendendo la coniugata trasposta della prima della (b) è:

$$(6) \quad u_i^H Ru_j = \lambda_i^* u_i^H u_j$$

od anche, essendo  $\lambda_i = \lambda_i^*$ :

$$(7) \quad u_i^H Ru_j = \lambda_i u_i^H u_j$$

Dal confronto della (7) con la seconda della (5) si deduce:

$$(8) \quad (\lambda_i - \lambda_j) u_i^H u_j = 0$$

che, essendo gli autovalori distinti comporta:

$$(9) \quad u_i^H u_j = 0 \quad i \neq j$$

Imponendo inoltre la normalizzazione si ha:

$$(10) \quad u_i^H u_j = \begin{cases} 1 & i = j \\ 0 & i \neq j \end{cases}$$

#### 3 - Diagonalizzazione di una matrice.

Se  $\{u_i\}_{i=1}^N$  denotano gli autovettori corrispondenti agli autovalori  $\{\lambda_i\}_{i=1}^N$ , supposti distinti, si può scrivere:

$$\begin{aligned}
 (11) \quad & \mathbf{R}\mathbf{u}_{-N} = \lambda_{-N}\mathbf{u}_{-N} \\
 & \dots\dots\dots \\
 & \mathbf{R}\mathbf{u}_N = \lambda_N\mathbf{u}_N
 \end{aligned}$$

che si può porre anche nella seguente forma matriciale:

$$(12) \quad \mathbf{R}[\mathbf{u}_{-N} \ \dots \ \mathbf{u}_0 \ \dots \ \mathbf{u}_N] = [\mathbf{u}_{-N} \ \dots \ \mathbf{u}_0 \ \dots \ \mathbf{u}_N] \begin{bmatrix} \lambda_{-N} & 0 & 0 & 0 & 0 \\ \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & \lambda_0 & 0 & 0 \\ \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & 0 & 0 & \lambda_N \end{bmatrix}$$

Denotando con  $\mathbf{U}$  e  $\mathbf{\Lambda}$  le matrici:

$$\begin{aligned}
 (13) \quad & \mathbf{U} = [\mathbf{u}_{-N} \ \dots \ \mathbf{u}_0 \ \dots \ \mathbf{u}_N] \\
 & \mathbf{\Lambda} = \text{diag}(\lambda_{-N}, \dots, \lambda_0, \dots, \lambda_N) = \begin{bmatrix} \lambda_{-N} & 0 & 0 & 0 & 0 \\ \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & \lambda_0 & 0 & 0 \\ \dots & \dots & \dots & \dots & \dots \\ 0 & 0 & 0 & 0 & \lambda_N \end{bmatrix}
 \end{aligned}$$

si scrive:

$$(14) \quad \mathbf{R}\mathbf{U} = \mathbf{U}\mathbf{\Lambda}$$

Dalla (14) si deduce:

$$(15) \quad \mathbf{R} = \mathbf{U}\mathbf{\Lambda}\mathbf{U}^{-1}$$

D'altra parte sulla base della (9) si ha:

$$(16) \quad \mathbf{U}^H \mathbf{U} = \mathbf{I}$$

che comporta  $\mathbf{U}^{-1} = \mathbf{U}^H$ . Si ha quindi:

$$(17) \quad \mathbf{R} = \mathbf{U}\mathbf{\Lambda}\mathbf{U}^{-1} = \mathbf{U}\mathbf{\Lambda}\mathbf{U}^H$$

e cioè

$$(18) \quad \mathbf{R} = \sum_{i=-N}^N \lambda_i \mathbf{u}_i \mathbf{u}_i^H$$