


(70)

•  $\frac{Y(z)}{X(z)} = 1 - z^{-1} \Rightarrow P_y(\omega) = |E(e^{j\omega})|^2 \text{Var}(d(t)) = |1 - e^{-j\omega}|^2 = 2(1 - \cos\omega)$



\* FILTRO DI KALMAN:

Il problema del tracciamento alla Kalman viene così impostato. Si consideri il seguente sistema dinamico:

$$\begin{aligned} x(t+1) &= Fx(t) + v_1(t) \\ y(t) &= Hx(t) + v_2(t) \end{aligned}$$

Si assume che  $y$  è un segnale misurato mentre  $x$  no.  $x(t)$  denota lo stato ed è un vettore di  $n$  componenti. Anche l'uscita  $y(t)$  è un vettore di  $p$  componenti.  $v_1(t)$  e  $v_2(t)$  sono disturbi definiti in modo probabilistico. Ipotesiamo che  $v_1(t)$  e  $v_2(t)$  siano numeri bianchi incommutati tra loro e a valore atteso nullo. Le matrici varianze di  $v_1(t)$  e  $v_2(t)$  verranno indicate con  $V_1$  e  $V_2$ . Quindi:

$$\begin{aligned} v_1(t) &\sim \text{WN}(0, V_1) \\ v_2(t) &\sim \text{WN}(0, V_2) \end{aligned} \quad * V_1, V_2, F, H \text{ sono comunque tutte matrici stab.}$$

Anche lo stato iniziale è un vettore aleatorio di incertezza. Se consideriamo l'istante iniziale ( $t=1$ ), e insieme alle variabili in  $t=1, N$  può essere così organizzato:

$$\begin{matrix} 1 \\ \vdots \\ N \end{matrix} \begin{bmatrix} x(1) \\ v_1(1) \\ \vdots \\ v_1(N) \\ v_2(1) \\ \vdots \\ v_2(N) \end{bmatrix}$$

\* Quindi  $y(t)$  rappresenta le dato e  $x(t)$  è incognita.

I problemi da possiamo affrontare sono: problemi di stima, di predizione, o di tracciamento. Breve se scriviamo:

$$\begin{aligned} R < N &\rightarrow \text{FILTRAGGIO} \\ R > N &\rightarrow \text{PREDIZIONE} \\ R = N &\rightarrow \text{REGOLARIZZAZIONE} \end{aligned}$$

Iniziamo con il problema di predizione. Siccome  $v_1(t)$  e  $v_2(t)$  vengono definiti in maniera probabilistica,  $x(t)$  e  $y(t)$  sono variabili casuali. Quindi ci siamo ricondotti ad un problema di stima da affrontare con i "metodi di Bayes". Si ricordi che lo stimatore di Bayes è:

(7)

$$\hat{g} = \left( g_m + \frac{\lambda g d}{\lambda d d} (d - d_m) \right) \rightarrow \text{STIMATORE GENERALE}$$

Nel nostro caso si ha:

$$\hat{x}(N+1|N) = x(N+1)_m + \Lambda_{x(N+1)d} \Lambda_{dd}^{-1} (d - d_m)$$

dove  $x(N+1)_m$  è il valore atteso di  $x(N+1)$ . Siccome i disturbi hanno valore atteso nullo, anche  $x(t|y(t))$  hanno valore atteso nullo. Quindi:

$$\hat{x}(N+1|N) = \Lambda_{x(N+1)d} \Lambda_{dd}^{-1} d \quad \text{con } d = y.$$

Ipotizziamo ora che  $g$  sia un'incognita del problema e  $d$  un insieme di dati. Per semplicità supponiamo che  $g$  sia scalare e  $d$  sia formato da due dati  $d(1), d(2)$ . Inoltre supponiamo che il valore atteso di  $d(1), d(2)$ ,  $g$  sia nullo. Generalizzando si ottiene:

$$\begin{bmatrix} g \\ d(1) \\ d(2) \end{bmatrix} \sim \left( \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix}, \begin{bmatrix} \lambda_{g1} & \lambda_{g2} & \lambda_{g3} \\ \lambda_{1g} & \lambda_{11} & \lambda_{12} \\ \lambda_{2g} & \lambda_{21} & \lambda_{22} \end{bmatrix} \right) \quad \text{dove } \lambda_{g1} = E[g d(1)].$$

Quindi in virtù della formula di Bayes la stima di  $g$  basata sul dato  $d(1)$  è:

$$E[g|d(1)] = \frac{\lambda_{g1} d(1)}{\lambda_{11}}$$

mentre la stima di  $g$  basata su  $d(1)$  e  $d(2)$  è:

$$E[g|d(1), d(2)] = [\lambda_{g1}, \lambda_{g2}] \begin{bmatrix} \lambda_{11} & \lambda_{12} \\ \lambda_{21} & \lambda_{22} \end{bmatrix}^{-1} \begin{bmatrix} d(1) \\ d(2) \end{bmatrix} \quad \lambda_{21} = \lambda_{12}$$

calcolando la matrice inversa e semplificando i termini si ottiene:

$$E[g|d(1), d(2)] = \frac{1}{\lambda_{11} \lambda^2} (-\lambda_{g1} \lambda_{21} + \lambda_{g2} \lambda_{11}) d(2) + \frac{1}{\lambda_{11} \lambda^2} (\lambda_{g1} \lambda_{22} - \lambda_{g2} \lambda_{12}) d(1)$$

dove si è posto:

$$\lambda^2 = \lambda_{22} - \frac{\lambda_{12}^2}{\lambda_{11}}$$

$$\text{Aggiungendo ora } \left( \frac{\lambda_{g1}}{\lambda_{11}} \right) d(1) \text{ si ha: } E[g|d(1), d(2)] = \frac{1}{\lambda_{11} \lambda^2} (-\lambda_{g1} \lambda_{21} + \lambda_{g2} \lambda_{11}) d(2) + \frac{1}{\lambda_{11} \lambda^2} (\lambda_{g1} \lambda_{22} - \lambda_{g2} \lambda_{12}) d(1) - \frac{\lambda_{g1} d(1)}{\lambda_{11}} + \frac{\lambda_{g1} d(1)}{\lambda_{11}}$$

Quindi:

$$E[g|d(1), d(2)] = \frac{1}{\lambda^2} \left( \lambda_{g2} - \lambda_{g1} \frac{\lambda_{12}}{\lambda_{11}} \right) d(2) + \frac{1}{\lambda^2} \left( \lambda_{g1} \frac{\lambda_{22}}{\lambda_{11}} - \lambda_{g2} \frac{\lambda_{12}}{\lambda_{11}} - \frac{\lambda_{g1} \lambda^2}{\lambda_{11}} \right) d(1) + \frac{\lambda_{g1} d(1)}{\lambda_{11}}$$

Sostituendo al posto di  $\lambda^2$  l'espressione prima trovata si ottiene:  $\lambda_{g1} \frac{\lambda_{22}}{\lambda_{11}} + (-) \lambda_{g2} \frac{\lambda_{12}}{\lambda_{11}} - \frac{\lambda_{g1} \lambda^2}{\lambda_{11}} = \frac{\lambda_{12}}{\lambda_{11}} (-\lambda_{g2} + \lambda_{g1} \frac{\lambda_{22}}{\lambda_{11}})$

Si ottiene alla fine:

$$E[g|d(1), d(2)] = \frac{\lambda_{g1}}{\lambda_{11}} d(1) + \frac{1}{\lambda^2} \left( \lambda_{g2} - \lambda_{g1} \frac{\lambda_{12}}{\lambda_{11}} \right) \left[ d(2) - \frac{\lambda_{12}}{\lambda_{11}} d(1) \right]$$

Si dice innovazione di  $d(2)$  rispetto a  $d(1)$  la seguente quantità:

$$e = d(2) - E[d(2)|d(1)] = d(2) - \frac{\lambda_{12}}{\lambda_{11}} d(1)$$

Si noti innanzitutto che l'innovazione è una variabile gaussiana perché deriva dalla somma di due variabili gaussiane ( $d(1), d(2)$ ). Le principali proprietà dell'innovazione sono:

1)  $E[e] = 0$

2)  $\lambda_{ee} = \text{Var}[e] = E\left[\left(d(2) - \frac{\lambda_{12}}{\lambda_{11}} d(1)\right)^2\right] = \lambda_{22} + \frac{\lambda_{12}^2}{\lambda_{11}^2} \lambda_{11} - 2 \frac{\lambda_{12}}{\lambda_{11}} \lambda_{12} = \lambda^2$

3)  $\lambda_{ge} = E\left[g\left(d(2) - \frac{\lambda_{12}}{\lambda_{11}} d(1)\right)\right] = \lambda_{g2} - \lambda_{g1} \frac{\lambda_{12}}{\lambda_{11}}$

4)  $\lambda_{1e} = E\left[d(1)\left(d(2) - \frac{\lambda_{12}}{\lambda_{11}} d(1)\right)\right] = \lambda_{12} - \frac{\lambda_{12}}{\lambda_{11}} \lambda_{11} = 0$

Quindi  $E[g|d(1), d(2)]$  può essere così scritta:  $E[g|d(1), d(2)] = \frac{\lambda_{g1}}{\lambda_{11}} d(1) + \frac{\lambda_{ge}}{\lambda_{ee}} e$ .


Si può perciò concludere affermando che:

$$E[g|d(1), d(2)] = E[g|d(1)] + E[g|e]$$

Si noti che non vale però la seguente relazione:  $E[g|d(1), d(2)] = E[g|d(1)] + E[g|d(2)]$ . L'unica volta in cui tale relazione è vera si ha quando:

$$E[d(2)|d(1)] = 0 \Rightarrow d(2) = e$$

Vediamo ora la interpretazione geometrica di quanto appena visto. Siamo  $g, d(1), d(2)$  da altri:



$$\begin{cases} \alpha = E[g|d(1)] \\ \beta = E[g|d(1), d(2)] \\ \delta = E[g|e] \end{cases}$$

Quindi la stima di  $g$  conoscendo  $d(1)$  e  $d(2)$  è data dalla proiezione di  $g$  sul piano.



La stima di  $g$  conoscendo solo  $d(1)$  e data invece della proiezione di  $g$  su  $d(1)$ . Vediamo ora la naturale estensione al caso vettoriale. Consideriamo:

$$\begin{bmatrix} g \\ d(1) \\ d(2) \end{bmatrix} \sim G \left( \begin{bmatrix} \varphi \\ \varphi \\ \varphi \end{bmatrix}, \begin{bmatrix} \Lambda_{g1} & \Lambda_{g2} & \Lambda_{g3} \\ \Lambda_{11} & \Lambda_{12} & \Lambda_{13} \\ \Lambda_{21} & \Lambda_{22} & \Lambda_{23} \end{bmatrix} \right)$$

dove  $\Lambda_{g1} = \Lambda_{1g}^T$ ;  $\Lambda_{2g}^T = \Lambda_{g2}$ ;  $\Lambda_{12} = \Lambda_{21}^T$ . Definiamo quindi anche l'innovazione nel caso vettoriale nel seguente modo:

$$e = d(2) - E[d(2)|d(1)] = d(2) - \Lambda_{21} \Lambda_{11}^{-1} d(1)$$

Si ha quindi:

$$E[g|d(1), d(2)] = \Lambda_{g1} \Lambda_{11}^{-1} d(1) + \Lambda_{g2} \Lambda_{ee}^{-1} e = E[g|d(1)] + E[ge].$$

Così si ottiene un'interpretazione geometrica rappresentata in precedenza. Analizziamo ora il predittore di Kalman. Nel problema della previsione ad un passo i dati sono costituiti dalle osservazioni dell'uscita  $y$ , dell'istante  $i$  o dell'istante  $N$ . Indichiamo con  $y^N$  tale insieme di dati. Quindi:

$$y^N = [y(N), y(N-1), \dots, y(1)]$$

Indichiamo poi con  $\mathcal{X}[y^N]$  lo spazio dello STATO DEL PASSATO. L'innovazione del dato  $N+1$  è data da:

$$e(N+1) = y(N+1) - E[y(N+1)|y^N]$$

Per come abbiamo già visto,  $E[y(N+1)|y^N]$  altro non è che la proiezione di  $y(N+1)$  su  $\mathcal{X}[y^N]$ . Si noti che l'innovazione è ortogonale al passato. Consideriamo ora un'altra variabile, che nella teoria di Kalman riveste una notevole importanza. Tale variabile prende il nome di ERRORE DI PREVISIONE DELLO STATO. La indichiamo con  $v(N+1)$ . Essa è così definita:

$$v(N+1) = x(N+1) - E[x(N+1)|y^N]$$

L'errore di previsione dello stato ha  $n$  componenti, tante quante è stato del sistema. Si può notare geometricamente che anche  $v(N+1)$  è ortogonale al passato. La previsione ottima ad un passo dell'uscita è data da:

$$\hat{y}(N+1|N) = E[y(N+1)|y^N]$$

↓

$$\hat{y}(N+1|N) = E[Hx(N+1) + v_2(N+1)|y^N] = HE[x(N+1)|y^N] + \underbrace{E[v_2(N+1)|y^N]}_{\text{STIMA A PRIORI}}$$

Postuliamo che il secondo addendo è nullo, mentre osservando la seguente equazione:

$$x(N+1) = Fx(N) + v_1(N) \Rightarrow x(N) \text{ dipende dal disturbo } v_1(i) \text{ fino al tempo } N-1, \text{ oltre alle due condizioni iniziali.}$$

Quindi:  $x(N) = p(v_1^{N-1}, x(1))$ . Perciò:

$$y(N) = p(v_1^{N-1}, x(1), v_2(N))$$

(71)

Concludendo si può notare che  $y^N$  è indipendente da  $v_2(w_{t+1})$  e quindi  $E[v_2(w_{t+1})|y^N]$  coincide con quella non condizionata  $E[v_2(w_{t+1})]$ . Quindi:

$$\hat{y}(w_{t+1}|N) = H \hat{x}(w_{t+1}|N)$$

Questo si ha perché  $E[v_2(w_{t+1})] = 0$ . Vogliamo ora la predizione ottima di  $x$ . Vogliamo cioè:

$$\hat{x}(w_{t+1}|N) = E[x(w_{t+1})|y^N] = E[x(w_{t+1})|y^{N-1}, y(w)] = \dots$$

Usiamo la formula di Bayes ricorsiva:

$$E[x(w_{t+1})|y^{N-1}] + E[x(w_{t+1})|e(w)]$$

↓

$$\begin{aligned} E[x(w_{t+1})|e(w)] &= \Lambda_{x(w_{t+1})e(w)} \Lambda_{e(w)e(w)}^{-1} e(w) \quad \text{con } e(w) = y(w) - \hat{y}(w|N-1) = \\ &= Hx(w) + v_2(w) - H\hat{x}(w|N-1) = \\ &= H(x(w) - \hat{x}(w|N-1)) + v_2(w) = \\ &= Hv(w) + v_2(w) \end{aligned}$$

Quindi:

$$\begin{aligned} \Lambda_{e(w)e(w)} &= E[e(w)e(w)'] = \\ &= E[Hv(w)v(w)'H'] + E[v_2(w)v_2(w)'] + \\ &+ E[Hv(w)v_2(w)'] + \dots = HE[v(w)v(w)']H' + E[v_2(w)v_2(w)'] = \\ &= HE[v(w)v(w)']H' + V_2 \end{aligned}$$

NB:  $v = T$

Chiamiamo:

$$P(w) = E[v(w)v(w)'] \rightarrow \text{matrice VARIANZA DELL'ERRORE DI PREVISIONE DI STATO.}$$

Si ha:  $\Lambda_{e(w)e(w)} = HP(w)H' + V_2$

Analogamente si ha:  $\Lambda_{x(w_{t+1})e(w)} = FP(w)H'$ . In conclusione si ha:

$$E[x(w_{t+1})|e(w)] = (FP(w)H')(HP(w)H' + V_2)^{-1} e(w)$$

Ma noi siamo partiti con:

$k(w) = \text{GUADAGNO DI KALMAN}$

$$\hat{x}(w_{t+1}|N) = E[x(w_{t+1})|y^{N-1}] + E[x(w_{t+1})|e(w)]$$

↓

$$\hat{F}\hat{x}(w_{t+1}|N) + k(w)e(w)$$

Concludendo:

S:  $x(t+1) = Fx(t) + v_1(t)$  → rumore.

↓

P:  $\hat{x}(w_{t+1}|N) = F\hat{x}(w_{t+1}|N-1) + k(w)e(w)$

con  $e(w) = y(w) - \hat{y}(w|N-1)$

$\hat{y}(w_{t+1}|N-1) = H\hat{x}(w_{t+1}|N-1)$

$k(w) = (FP(w)H')(HP(w)H' + V_2)^{-1}$



Si noti che l'equazione del predittore di Kalman può essere così inizializzata:

$$\begin{cases} \hat{x}(1|0) = ? \\ P(1) = ? \end{cases} \text{ ma dati } y(1), y(2), \dots, y(N)$$

$$\hat{x}(1|0) = E[x(1) | y(0), y(-1), \dots], \text{ ma } E[x(1)] = a$$

Inoltre:  $\text{Var}[x(1)] = P(1)$  e quindi:

$$v(1) = x(1) - \hat{x}(1|0) = \dots$$

In generale si noti che:

$$\hat{x}(2|1) = E[x(2) | y(1)] = \Lambda_{x(2)y(1)} \Lambda_{y(1)y(1)}^{-1} y(1) = F P_1 H^T (H P_1 H^T + V_2)^{-1} y(1).$$

Tenendo conto che:  $e(w) = y(w) - \hat{y}(w|w-1) = y(w) - H \hat{x}(w|w-1)$ ,  $\hat{x}(w+1|w) = F \hat{x}(w|w-1) + K(w)e(w)$   
 $\downarrow$  (trasferimento al tempo  $w+1$ ).  
 $\hat{x}(1|0) = a$

Quindi in assenza di informazioni la stima più ragionevole di  $x(1)$  è quella del valore atteso, se è noto. Andizziamo ora il problema del filtraggio o del Kalman. Proviamo prima ad estendere la teoria vista precedentemente sul predittore ad un passo di Kalman, al caso di predittore a più passi. A tale scopo consideriamo:

$$\begin{aligned} x(t+1) &= Fx(t) + v_1(t) \\ y(t) &= Hx(t) + v_2(t) \end{aligned}$$

dove  $v_1(t)$  e  $v_2(t)$  sono numeri bianchi a valore atteso nullo, eventualmente correlati fra loro.

Quindi:

$$E[v_1(t_1) v_2(t_2)] = \gamma_{12} \delta(t_2 - t_1) \text{ per } i=1,2 \text{ e } j=1,2.$$

Il predittore ottimo ad  $R$  passi con  $R \geq 1$  ha il compito di stimare la variabile casuale  $x(N+R)$  a partire dai dati fino a  $N$  e cioè dalle osservazioni di  $y(1), y(2), \dots$ . Quindi il predittore ottimo  $\hat{x}(N+R|N)$  sarà:

$$\hat{x}(N+R|N) = E[x(N+R) | y^N]$$

Ricordandosi che:

$$x(N+R) = Fx(N+R-1) + v_1(N+R-1)$$

e che per ogni  $R \geq 1$ , il campione  $v_1(N+R-1)$  è incorrelato con i dati fino ad  $N$ , si ha:

$$\hat{x}(N+R|N) = F \hat{x}(N+R-1|N)$$

Iterando si avrà:

$$\hat{y}(N+R|N) = F^{R-1} \hat{x}(N+R|N)$$

Per quanto riguarda  $e$ -uscita, si ha che per  $R \geq 1$ ,  $v_2(N+R)$  risulta incorrelato con i dati fino a  $N$ . Quindi la predizione ottima sarà:

$$\hat{x}(N+R|N) = H \hat{x}(N+R|N)$$

Quindi il predittore ottimo a più passi deve essere stato si ricava a partire da quello ad un passo. Facciamo ora un piccolo passo ancora indietro. Precedentemente si è usata la variabile da essere di stima deve stato  $v(w)$ . Tale variabile è una matrice  $n \times n$ .

(76)

Tale matrice er abbiamo indicata con  $P(w)$ . Poiché:  $v(w+1) = x(w+1) - \hat{x}(w+1|w)$  o sapendo che  $x(t+1) = Fx(t) + V_1(t)$  ed  $\hat{x}(w+1|w) = F\hat{x}(w|w-1) + k(w)e(w)$  si ha:

$$v(w+1) = [Fx(w) + V_1(w) - F\hat{x}(w|w-1) + k(w)e(w)]$$

$$\Downarrow$$

$$v(w+1) = [Fv(w) + V_1(w) + k(w)e(w)]$$

Siccome  $e(w) = y(w) - \hat{y}(w|w-1)$  si ha:

$$v(w+1) = [Fv(w) + V_1(w) + k(w)[y(w) - \hat{y}(w|w-1)]] =$$

$$= [Fv(w) + V_1(w) + k(w)(Hx(w) + V_2(w) - H\hat{x}(w|w-1))] =$$

$$= [Fv(w) + V_1(w) + k(w)(Hv(w) + V_2(w))] = \underline{[F - k(w)H]v(w) + V_1(w) - k(w)V_2(w)}$$

Quindi da quest'ultima relazione si può calcolare la matrice varianza dell'errore di previsione dello stato in questo modo:

$$\begin{aligned} P(w+1) &= \text{Var}[v(w+1)] = E[v(w+1)v(w+1)^T] = E[(F - k(w)H)v(w) + V_1(w) - k(w)V_2(w)] \\ &\quad \cdot E[(F - k(w)H)v(w) + V_1(w) - k(w)V_2(w)]^T + E[V_1(w)V_1(w)^T] + E[k(w)V_2(w)V_2(w)^T k(w)^T] \\ &\quad + E[(F - k(w)H)v(w)V_1(w)^T] + E[(F - k(w)H)v(w)V_2(w)^T] k(w)^T \\ &\quad - E[V_1(w)V_2(w)^T] k(w)^T + E[V_1(w)V_1(w)^T] \\ &\quad \cdot (F - k(w)H)^T - E[k(w)V_2(w)v(w)^T (F - k(w)H)^T] \end{aligned}$$

$$\Downarrow$$

$$P(w+1) = (F - k(w)H)P(w)(F - k(w)H)^T + V_1 + k(w)V_2 k(w)^T$$

Sviluppando il prodotto nel primo addendo si ha:  $P(w+1) = FP(w)F^T - k(w)HP(w)F^T - FP(w)H^T k(w)^T +$   
 Quest'ultima espressione può essere così riscritta:  $+ k(w)HP(w)H^T k(w)^T + V_1 + k(w)V_2 k(w)^T.$

$$\underline{k(w)HP(w)H^T k(w)^T + k(w)V_2 k(w)^T = k(w)(HP(w)H^T + V_2)k(w)^T}$$

Siccome però  $k(w) = FP(w)H^T [HP(w)H^T + V_2]^{-1}$  si ha:

$$k(w)HP(w)H^T k(w)^T + k(w)V_2 k(w)^T = FP(w)H^T [HP(w)H^T + V_2]^{-1} (HP(w)H^T + V_2) k(w)^T$$

$$\Downarrow$$

$$\underline{k(w)HP(w)H^T k(w)^T + k(w)V_2 k(w)^T = FP(w)H^T k(w)^T}$$

Perciò:

$$P(w+1) = FP(w)F^T - k(w)HP(w)F^T + V_1$$

$$\text{Ma } k(w) = FP(w)H^T [HP(w)H^T + V_2]^{-1} \Rightarrow P(w+1) = FP(w)F^T + V_1 - FP(w)H^T (HP(w)H^T + V_2)^{-1} HP(w)F^T$$

$$\Downarrow$$

$$\underline{P(w+1) = FP(w)F^T + V_1 - k(w)(HP(w)H^T + V_2)k(w)^T}$$

Quest'ultima equazione prende il nome di EQUAZIONE DI RICCATI ALLE DIFFERENZE (DAE).