

Lezione 3 — Ottobre 19

Docente: Luca Schenato

Stesori: Cuccato Davide, De Franceschi Igor, Sartor Giorgio

3.1 Filtro di Kalman in forma di informazione o di varianza inversa

Il filtro di Kalman in forma di informazione é una manipolazione delle consuete equazioni del filtro al fine di dar loro una forma particolarmente utile dal punto di vista implementativo, in quanto richiede l'inversione di una matrice $n \times n$ e non $m \times m$; in numerose applicazioni si ha $m > n$ e dunque la complessità di calcolo risulta diminuita. Tale manipolazione si basa sul ben noto *lemma di inversione di matrice*, di seguito riportato, la cui dimostrazione può essere trovata in un qualsiasi testo di algebra lineare:

Lemma 3.1. *Siano A e D due matrici quadrate invertibili; siano U e V altre due matrici di dimensioni opportune. Vale:*

$$(A + UDV)^{-1} = A^{-1} - A^{-1}U(D^{-1} + VA^{-1}U)^{-1}VA^{-1} \quad (3.1)$$

Si ricordino le equazioni relative al passo di aggiornamento del Filtro di Kalman:

$$P_{k+1|k+1} = P_{k+1|k} - P_{k+1|k}C^T (CP_{k+1|k}C^T + R)^{-1} CP_{k+1|k} \quad (3.2)$$

$$\hat{x}_{k+1|k+1} = \hat{x}_{k+1|k} + P_{k+1|k}C^T (CP_{k+1|k}C^T + R)^{-1} (y_{k+1} - C\hat{x}_{k+1|k}) \quad (3.3)$$

Per quel che riguarda la prima equazione relativa alla varianza di errore si ricava subito che la parte a destra dell' Equazione (3.1) coincide con l'Equazione (3.2) tramite la sostituzione $A^{-1} = P_{k+1|k}$, $U = C$, $D^{-1} = R$, $V = C^T$, da cui si ricava immediatamente:

$$P_{k+1|k+1} = (P_{k+1|k}^{-1} + C^T R^{-1} C)^{-1} \quad (3.4)$$

Per quel che riguarda l'Equazione (3.3) di aggiornamento dello stato invece si trova:

$$\begin{aligned}
\hat{x}_{k+1|k+1} &= \hat{x}_{k+1|k} + P_{k+1|k} C^T (C P_{k+1|k} C^T + R)^{-1} (y_{k+1} - C \hat{x}_{k+1|k}) \\
&= (I - P_{k+1|k} C^T (C P_{k+1|k} C^T + R)^{-1} C) \hat{x}_{k+1|k} + P_{k+1|k} C^T (C P_{k+1|k} C^T + R)^{-1} y_{k+1} \\
&= (I - P_{k+1|k} C^T (C P_{k+1|k} C^T + R)^{-1} C) P_{k+1|k} P_{k+1|k}^{-1} \hat{x}_{k+1|k} + \\
&\quad + P_{k+1|k} C^T (R^{-1} - R^{-1} C (P_{k+1|k}^{-1} + C^T R^{-1} C)^{-1} C^T R^{-1}) y_{k+1} \\
&= (P_{k+1|k} - P_{k+1|k} C^T (C P_{k+1|k} C^T + R)^{-1} C P_{k+1|k}) P_{k+1|k}^{-1} \hat{x}_{k+1|k} + \\
&\quad + (P_{k+1|k} - P_{k+1|k} C^T R^{-1} C (P_{k+1|k}^{-1} + C^T R^{-1} C)^{-1}) C^T R^{-1} y_{k+1} \\
&= P_{k+1|k+1} P_{k+1|k}^{-1} \hat{x}_{k+1|k} + \\
&\quad + (P_{k+1|k} (P_{k+1|k}^{-1} + C^T R^{-1} C) - P_{k+1|k} C^T R^{-1} C) (P_{k+1|k}^{-1} + C^T R^{-1} C)^{-1} C^T R^{-1} y_{k+1} \\
&= P_{k+1|k+1} P_{k+1|k}^{-1} \hat{x}_{k+1|k} + P_{k+1|k+1} C^T R^{-1} y_{k+1}
\end{aligned}$$

da cui si deduce che

$$\hat{x}_{k+1|k+1} = P_{k+1|k+1} (P_{k+1|k}^{-1} \hat{x}_{k+1|k} + C^T R^{-1} y_{k+1}) \quad (3.5)$$

OSSERVAZIONI:

- Nel Filtro di Kalman classico, le equazioni di aggiornamento (3.2)-(3.3) richiedono l'inversione **ad ogni passo** della matrice $(C P_{k+1|k} C^T + R) \in \mathbb{R}^{m \times m}$ che ha rango uguale alla dimensione del vettore di misura y , mentre le equazioni del Filtro di Kalman in forma di informazione (3.4)-(3.5) richiedono l'inversione di matrici $P_{k+1|k+1} \in \mathbb{R}^{n \times n}$ che hanno la dimensione dello stato x . Quindi da un punto di vista computazionale e' possibile scegliere la forma piu' appropriata e quindi la complessità del filtro di Kalman e' $O(\min(m^3, n^3))$, in quanto la complessità dell'inversione di una matrice è dell'ordine del cubo della sua dimensione.
- Si definisca $z_{k|h} \triangleq P_{k|h}^{-1} \hat{x}_{k|h}$ $Z_{k|h} \triangleq P_{k|h}^{-1}$ $i_k \triangleq C^T R^{-1} y_k$, dove i_k prende il nome di **informazione** relativa alla misura k-esima. Le equazioni del filtro di Kalman relative all'aggiornamento possono essere riscritte come

$$z_{k+1|k+1} = z_{k+1|k} + i_{k+1} \quad (3.6)$$

$$Z_{k+1|k+1} = Z_{k+1|k} + C^T R^{-1} C \quad (3.7)$$

Si noti che $Z_{k|h}$ è l'inversa di una varianza, quindi piu' grande è tale matrice, minore è l'errore di stima. Inoltre le equazioni del predittore in questo nuovo spazio di stato sono date da

$$z_{k+1|k} = Z_{k+1|k} A Z_{k|k}^{-1} z_{k|k} \quad (3.8)$$

$$Z_{k+1|k} = (A Z_{k|k}^{-1} A^T + Q)^{-1} \quad (3.9)$$

che si ottengono a partire da $\hat{x}_{k+1|k} = A \hat{x}_{k|k}$ e $P_{k+1|k} = A P_{k|k} A^T + Q$ e dalle definizioni di $z_{k|h}$ e $Z_{k|h}$.

Tali equazioni, ottenute da quelle canoniche di Kalman applicando le posizioni sopra definite, prendono il nome di **Filtro di Kalman in forma d'informazione**.

ESEMPIO 1 Consideriamo il caso:

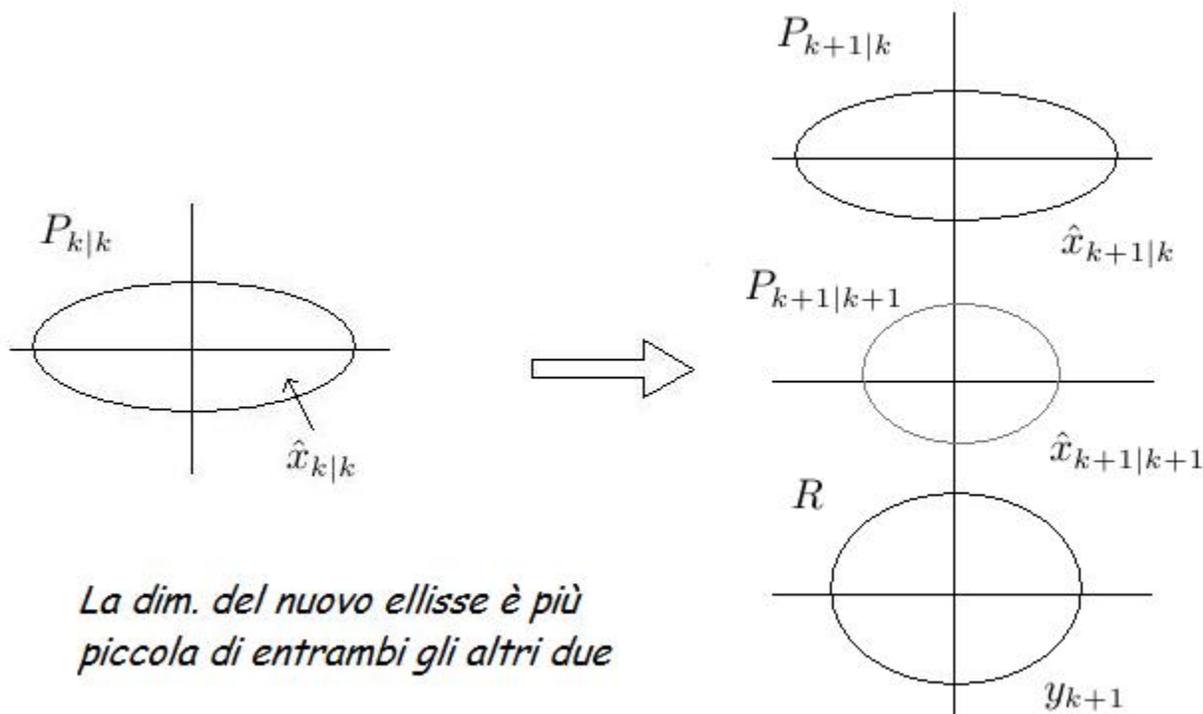
$$\begin{cases} x_{k+1} = Ax_k + w_k \\ y_k = x_k + v_k \end{cases}$$

dove si può interpretare y_k come una misura rumorosa dello stato.

Si ha che:

$$\hat{x}_{k+1|k+1} = P_{k+1|k+1}(P_{k+1|k}^{-1}\hat{x}_{k+1|k} + R^{-1}y_{k+1})$$

dunque l'uscita del filtro risulta essere la somma pesata della stima precedente e delle misure; se il rumore $v(\cdot)$ ha varianza elevata, ovvero le misure sono molto rumorose, la matrice di peso R^{-1} risulterà composta da elementi piccoli rispetto a $P_{k+1|k}^{-1}$, quindi le misure conterranno poco rispetto alla stima. Se viceversa è l'errore di stima ad avere varianza elevata rispetto al rumore di misura, saranno le stime ad avere peso minore nella somma.



Consideriamo ora il caso di una matrice C generica di dimensioni $m \times n$ dove per $\text{rank}(C) = n < m$. Questa condizione serve a garantire che la matrice $C^T R^{-1} C$ sia invertibile. Allora:

$$\begin{aligned} \hat{x}_{k+1|k+1} &= P_{k+1|k+1}(P_{k+1|k}^{-1}\hat{x}_{k+1|k} + C^T R^{-1}y_{k+1}) \\ &= P_{k+1|k+1}(P_{k+1|k}^{-1}\hat{x}_{k+1|k} + (C^T R^{-1}C)(C^T R^{-1}C)^{-1}C^T R^{-1}y_{k+1}) \\ &= P_{k+1|k+1}(P_{k+1|k}^{-1}\hat{x}_{k+1|k} + (P_{k+1}^y)^{-1}\hat{x}_{k+1}^y) \end{aligned}$$

É quindi possibile interpretare $\hat{x}_{k+1}^y = (C^T R^{-1} C)^{-1} C^T R^{-1} y_{k+1}$ come una stima dello stato basata sulla misura all'istante k , con $(P_{k+1}^y)^{-1} = C^T R^{-1} C$ la relativa inversa della matrice di varianza d'errore, in corrispondenza a quanto fatto nel caso precedente.

Infine consideriamo il caso in cui $n > m$, e quindi $C^T R^{-1} C$ non é piú invertibile; sia, ad esempio:

$$C = \begin{bmatrix} 1 & 0 \end{bmatrix}, R = r, y_k \in \mathbb{R}$$

perciú:

$$C^T R^{-1} C = \begin{bmatrix} r^{-1} & 0 \\ 0 & 0 \end{bmatrix} = (P_{k+1}^y)^{-1}$$

Tale matrice non é invertibile ma é possibile fare un ragionamento intuitivo. Assumiamo che anche la seconda componente dello stato sia direttamente osservabile, ma affetta da un rumore molto elevato, cioè:

$$\bar{y}_{k+1} = \begin{bmatrix} y_{k+1} \\ \xi_{k+1} \end{bmatrix}, \bar{C} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}, \bar{R} = \begin{bmatrix} r & 0 \\ 0 & \sigma^2 \end{bmatrix}, \sigma^2 \gg r$$

dove ξ_{k+1} rappresenta la misura fittizia. Da un punto di vista pratico i due modelli dovrebbero dare risultati molto simili in quanto il secondo sensore non apporta informazione essendo affetto da rumore molto elevato. Infatti in questo caso:

$$\bar{C}^T \bar{R}^{-1} \bar{C} = \begin{bmatrix} r^{-1} & 0 \\ 0 & \sigma^{-2} \end{bmatrix} \approx \begin{bmatrix} r^{-1} & 0 \\ 0 & 0 \end{bmatrix} = (P_{k+1}^y)^{-1}$$

Nel momento in cui viene fatto l'aggiornamento dello stato con questo modello si ha:

$$\bar{i}_{k+1} = \bar{C}^T \bar{R}^{-1} \bar{y}_{k+1} = \begin{bmatrix} r^{-1} y_{k+1} \\ \sigma^{-2} \xi_{k+1} \end{bmatrix} \approx \begin{bmatrix} r^{-1} y_{k+1} \\ 0 \end{bmatrix} = C^T R^{-1} y_{k+1} = i_{k+1}$$

quindi come era da aspettarsi la misura ξ_{k+1} viene "pesata" poco in quanto molto rumorosa.

È possibile quindi interpretare l'informazione $i_k = C^T R^{-1} y_{k+1}$ come la proiezione della stima dello stato ottenibile dalla sola misura y_{k+1} tenendo conto sia della varianza del rumore R sia dell' "osservabilità" diretta dello stato dato da C . Con ragionamenti simili, è possibile interpretare la matrice $C^T R^{-1} C$ come l'inversa dell'incertezza data dalla stima ottenibile con la sola misura y_{k+1} , quindi le direzioni che definiscono il sottospazio relativo al suo nucleo corrispondono a direzioni in cui l'incertezza è totale.

ESEMPIO 2 Supponiamo di voler stimare l'evoluzione dello stato utilizzando le misure ottenute tramite il modello lineare:

$$\begin{cases} x_{i+1} = Ax_i + w_i \\ y_i = Cx_i + v_i \end{cases}$$

a cui aggiungiamo le seguenti ipotesi:

- $x_k, y_k \in \mathbb{R}$
- $w_i = 0 \implies Q = q = 0$
- $v_i \sim \mathcal{N}(0, \sigma^2) \implies R = r = \sigma^2$
- $A = 1, C = 1$
- $P_0 = \infty, \bar{x}_0 = 0^1$

Da queste ipotesi si ricava che $x_{k+1} = x_k = \dots = x_0 = \theta$, cioè il parametro da stimare non cambia nel tempo. Applichiamo a questo modello semplificato il filtro di Kalman in forma di informazione ottenendo le seguenti equazioni:

$$P_{k+1|k} = P_{k|k}$$

$$\hat{x}_{k+1|k} = \hat{x}_{k|k}$$

$$P_{k+1|k+1} = (P_{k|k}^{-1} + \frac{1}{\sigma^2})^{-1}$$

$$\hat{x}_{k+1|k+1} = P_{k+1|k+1} (P_{k|k}^{-1} \hat{x}_{k|k} + \frac{1}{\sigma^2} y_{k+1})$$

Calcoliamo adesso la stima del filtro di Kalman per ogni passo partendo dallo stato iniziale:

$$P_{0|0} = P_0 = \infty \implies P_0^{-1} = 0$$

$$\hat{x}_{0|0} = \bar{x}_0 = 0$$

$$P_{1|1} = \sigma^2$$

$$\hat{x}_{1|1} = y_1$$

$$P_{2|2} = (\frac{1}{\sigma^2} + \frac{1}{\sigma^2})^{-1}$$

$$\hat{x}_{2|2} = \frac{\sigma^2}{2} (\frac{1}{\sigma^2} \hat{x}_{1|1} + \frac{1}{\sigma^2} y_2) = \frac{y_1 + y_2}{2}$$

Si può intuire facilmente come proseguiranno le iterazioni e si trova in generale:

$$P_{k|k} = \frac{\sigma^2}{k}$$

$$\hat{x}_{k|k} = \frac{1}{k} \sum_{i=1}^k y_i = \frac{1}{k} ((k-1) \hat{x}_{k-1|k-1} + y_k) = \frac{k-1}{k} \hat{x}_{k-1|k-1} + \frac{1}{k} y_k$$

Si può notare come all'aumentare dei campioni la misura venga pesata sempre meno mentre la stima sempre di più. Inoltre la varianza d'errore converge a zero, quindi si può quindi affermare che la stima del filtro di Kalman converge al valore esatto del parametro incognito $x_k = x_0 = \theta$ all'aumentare dei campioni.

Se si volesse determinare quanti campioni sono sufficienti affinché la stima del filtro di Kalman

¹Il fatto che la varianza iniziale P_0 sia infinita rende comunque ininfluente il valore iniziale \bar{x}_0 .

sia sufficientemente accurata, é necessario determinare l'intervallo di confidenza utilizzando la formula:

$$\theta \in \left[\hat{x}_{k|k} - \alpha \frac{\sigma}{\sqrt{k}}, \hat{x}_{k|k} + \alpha \frac{\sigma}{\sqrt{k}} \right]$$

dove $\alpha = 1.96$, 2.57 con confidenza rispettivamente del 95% e 99%, che si possono ottenere dall'ipotesi di gaussianità del rumore, cioè

$$\mathbb{P} \left[\theta \in \left[\hat{x}_{k|k} - \alpha \frac{\sigma}{\sqrt{k}}, \hat{x}_{k|k} + \alpha \frac{\sigma}{\sqrt{k}} \right] \right] \geq 1 - \delta$$

dove $\delta = 0.05$ per $\alpha = 1.96$ e $\delta = 0.01$ per $\alpha = 2.57$.