

1.1 Variabili aleatorie e nozioni preliminari

Le definizioni di questa sezione si trovano in qualsiasi testo di processi stocastici lineari ed in particolare nel Capitolo 2 in [1].

Definizione 1.1. Una matrice simmetrica $\Sigma = \Sigma^T \in \mathbb{R}^{n \times n}$ si dice *semidefinita positiva*, $\Sigma \geq 0$, se $x^T \Sigma x \geq 0 \forall x \in \mathbb{R}^n$.

Definizione 1.2. Una matrice simmetrica $\Sigma = \Sigma^T \in \mathbb{R}^{n \times n}$ si dice *definita positiva*, $\Sigma > 0$, se $x^T \Sigma x \geq 0 \forall x \in \mathbb{R}^n$ e $x^T \Sigma x = 0 \Leftrightarrow x = 0$.

Definizione 1.3. La *traccia* $\text{tr} : \mathbb{R}^{n \times n} \rightarrow \mathbb{R}$ di una matrice $A \in \mathbb{R}^{n \times n}$ è definita come $\text{tr}(A) = \sum_{i=1}^n A_{ii}$ dove A_{ii} è elemento sulla diagonale della matrice A . La traccia gode delle seguenti proprietà:

1. $\text{tr}(ABC) = \text{tr}(BCA) = \text{tr}(CAB)$, dove le matrici A, B, C hanno dimensione opportuna;
2. Sia $x \in \mathbb{R}^n$ e $Q \geq 0$, allora $\|x\|_Q^2 = x^T Q x = \text{tr}(x^T Q x) = \text{tr}(Q x x^T)$;
3. Se $Q \geq 0$ e $P_1 \geq P_2$, allora $\text{tr}(Q P_1) \geq \text{tr}(Q P_2)$;
4. $P_1 \geq P_2 \implies \text{tr}(P_1) \geq \text{tr}(P_2)$, ma non viceversa.

Definizione 1.4. Una variabile aleatoria si dice *gaussiana* ed è indicata con $x \sim \mathcal{N}(\mu, \Sigma)$, dove $\mu \in \mathbb{R}^n$ e $\Sigma \in \mathbb{R}^{n \times n}$, $\Sigma > 0$, se la sua densità di probabilità è data da

$$p(x) = \frac{1}{\sqrt{(2\pi)^n \det \Sigma}} e^{-\frac{1}{2}(x-\mu)^T \Sigma^{-1}(x-\mu)}.$$

È facile verificare che $\mathbb{E}[x] = \mu$ e $\text{Var}(x) = \mathbb{E}[(x - \mathbb{E}[x])(x - \mathbb{E}[x])^T] = \Sigma$. La condizione $\Sigma > 0$ può essere rilassata a $\Sigma \geq 0$ tramite l'introduzione delle distribuzioni di Dirac (cioè le variabili di incertezza nulla hanno una d.d.p. assimilabile ad un impulso di Dirac nell'origine).

Definizione 1.5. Sia $A \in \mathbb{R}^{n \times m}$. Si definisce *pseudoinversa* della matrice A , l'unica matrice $A^\dagger \in \mathbb{R}^{m \times n}$ che soddisfa le seguenti proprietà:

$$\begin{aligned} A^\dagger A A^\dagger &= A^\dagger & A A^\dagger A &= A \\ (A A^\dagger)^T &= A A^\dagger & (A^\dagger A)^T &= A^\dagger A. \end{aligned}$$

Dalla definizione segue che

1. La pseudoinversa della matrice di soli zeri $0_{nm} \in 0^{n \times m}$, è data da $0_{nm}^\dagger = 0_{mn}$;
2. Se la matrice $A \in \mathbb{R}^{n \times n}$ è invertibile allora $A^\dagger = A^{-1}$;
3. Data la matrice $A = \begin{bmatrix} A_{11} & 0_{nm} \\ 0_{pq} & 0_{pm} \end{bmatrix}$ la sua pseudoinversa è data da $A^\dagger = \begin{bmatrix} A_{11}^\dagger & 0_{qp} \\ 0_{mn} & 0_{mp} \end{bmatrix}$.

Elenchiamo ora una serie di semplici proprietà che risulteranno molto utili per derivare in maniera chiara e semplice il filtro di Kalman:

Proposizione 1.1. Siano x, y due variabili aleatorie (non necessariamente gaussiane) con densità di probabilità $p(x, y)$ e sia $g(x, y)$ una generica funzione misurabile. Allora

$$\mathbb{E}_{xy}[g(x, y)] = \mathbb{E}_y[\mathbb{E}_{x|y}[g(x, y)|y]]$$

Dimostrazione: Con un piccolo abuso di notazione indichiamo con \mathbb{E}_x per indicare chiaramente rispetto a quale variabile aleatoria è calcolata. In genere tale pedice non viene indicato ed è sottointeso. Infatti

$$\begin{aligned} \mathbb{E}[g(x, y)] &= \mathbb{E}_{xy}[g(x, y)] = \int_x \int_y g(x, y) p(x, y) dx dy = \int_x \int_y g(x, y) p(x|y) p(y) dx dy \\ &= \int_y \left(\int_x g(x, y) p(x|y) dx \right) p(y) dy = \int_y \mathbb{E}_{x|y}[g(x, y)|y] p(y) dy = \mathbb{E}_y[\mathbb{E}_{x|y}[g(x, y)|y]] \end{aligned}$$

□

Proposizione 1.2. Siano $x \in \mathbb{R}^n$ e $y \in \mathbb{R}^m$ due variabili congiuntamente gaussiane, cioè:

$$p(x, y) \sim \mathcal{N} \left(\begin{bmatrix} \mu_x \\ \mu_y \end{bmatrix}, \begin{bmatrix} \Sigma_{xx} & \Sigma_{xy} \\ \Sigma_{yx} & \Sigma_{yy} \end{bmatrix} \right)$$

1. La combinazione lineare di variabili aleatorie gaussiane è ancora una variabile aleatoria gaussiana. Infatti se $z = Ax + By$ dove A, B sono matrici di dimensioni opportune, allora $p(z) \sim \mathcal{N}(\mu_z, \Sigma_z)$, dove

$$\begin{aligned} \mu_z &= \mathbb{E}[Ax + By] = A\mu_x + B\mu_y \\ \Sigma_z &= \mathbb{E} \left[(Ax + By - A\mu_x - B\mu_y) (Ax + By - A\mu_x - B\mu_y)^T \right] \\ &= \mathbb{E} \left[\left([A \ B] \begin{bmatrix} x - \mu_x \\ y - \mu_y \end{bmatrix} \right) \left([A \ B] \begin{bmatrix} x - \mu_x \\ y - \mu_y \end{bmatrix} \right)^T \right] \\ &= [A \ B] \mathbb{E} \left[\begin{bmatrix} x - \mu_x \\ y - \mu_y \end{bmatrix} \begin{bmatrix} x - \mu_x \\ y - \mu_y \end{bmatrix}^T \right] [A \ B]^T \\ &= [A \ B] \begin{bmatrix} \Sigma_{xx} & \Sigma_{xy} \\ \Sigma_{yx} & \Sigma_{yy} \end{bmatrix} \begin{bmatrix} A^T \\ B^T \end{bmatrix} \end{aligned}$$

2. Il condizionamento di variabili aleatorie gaussiane è ancora una variabile aleatoria gaussiana di d.d.p. $p(x|y) = \mathcal{N}(\mu_{x|y}, \Sigma_{x|y})$.

Se $\Sigma_{yy} > 0$ allora

$$\mu_{x|y} = \mu_x + \Sigma_{xy}\Sigma_{yy}^{-1}(y - \mu_y) \quad \Sigma_{x|y} = \Sigma_{xx} - \Sigma_{xy}\Sigma_{yy}^{-1}\Sigma_{yx}$$

Se $\Sigma_{yy} \geq 0$ la media e la varianza sono date da

$$\mu_{x|y} = \mu_x + \Sigma_{xy}\Sigma_{yy}^\dagger(y - \mu_y) \quad \Sigma_{x|y} = \Sigma_{xx} - \Sigma_{xy}\Sigma_{yy}^\dagger\Sigma_{yx}.$$

Dimostrazione: Vedere Teorema 2.3 e 2.6 in [1]. □

Passiamo ora ad enunciare uno dei più importanti teoremi che riguardano la stima di variabili aleatorie.

Teorema 1.1. Siano $x \in \mathbb{R}^n, y \in \mathbb{R}^m$ due variabili aleatorie (non necessariamente gaussiane), e sia $g : \mathbb{R}^m \rightarrow \mathbb{R}^n$ una qualsiasi funzione misurabile. Definiamo $\tilde{x}_g = g(y)$ stimatore di x ed $e_g = x - g(y) = x - \tilde{x}_g$ il corrispondente errore di stima, a loro volta variabili aleatorie. Lo stimatore $\hat{x} = \hat{g}(y) = \mathbb{E}[x|y]$ è detto **stimatore ottimo a minima varianza** o **stimatore ottimo in media quadratica**, poiché possiede la seguente proprietà:

$$\mathbb{E}[(x - \hat{x})(x - \hat{x})^T] \leq \mathbb{E}[(x - \tilde{x}_g)(x - \tilde{x}_g)^T] \quad \forall g(\cdot). \quad (1.1)$$

La precedente proprietà implica che

$$\mathbb{E}[||x - \hat{x}||_Q^2] \leq \mathbb{E}[||x - \tilde{x}_g||_Q^2] \quad \forall g(\cdot) \quad \forall Q \geq 0. \quad (1.2)$$

Se indichiamo con $e = x - \hat{x}$ l'errore dello stimatore ottimo, si ha che

$$\mathbb{E}[e\hat{g}(y)^T] = 0 \quad (1.3)$$

cioè l'errore dello stimatore ottimo è scorrelato dalla sua stima.

Lo stimatore ottimo è inoltre corretto (unbiased) in quanto

$$\mathbb{E}[\hat{x}] = \mathbb{E}_y[\hat{g}(y)] = \mathbb{E}[x]. \quad (1.4)$$

Dimostrazione: Questo teorema è simile al Teorema 2.2 in [1]. Definiamo per semplicità $\Delta g(y) = \hat{g}(y) - g(y)$.

$$\begin{aligned} \mathbb{E}[(x - \tilde{x}_g)(x - \tilde{x}_g)^T] &= \mathbb{E}_{xy}[(x - \tilde{x}_g)(x - \tilde{x}_g)^T] = \mathbb{E}_{xy}[(x - g(y))(x - g(y))^T] = \\ &= \mathbb{E}_{xy}[(x - g(y) + \hat{g}(y) - \hat{g}(y))(x - g(y) + \hat{g}(y) - \hat{g}(y))^T] \\ &= \mathbb{E}_y[\mathbb{E}_{x|y}[(x - g(y) + \hat{g}(y) - \hat{g}(y))(x - g(y) + \hat{g}(y) - \hat{g}(y))^T | y]] \\ &= \mathbb{E}_y[\mathbb{E}_{x|y}[(x - \hat{g}(y))(x - \hat{g}(y))^T + (x - \hat{g}(y))\Delta g(y)^T + \Delta g(y)(x - \hat{g}(y))^T + \Delta g(y)\Delta g(y)^T | y]] \\ &= \mathbb{E}_y[\mathbb{E}_{x|y}[(x - \hat{g}(y))(x - \hat{g}(y))^T | y] + (\mathbb{E}_{x|y}[x|y] - \hat{g}(y))\Delta g(y)^T + \Delta g(y)(\mathbb{E}_{x|y}[x|y] - \hat{g}(y))^T + \\ &\quad + \Delta g(y)\Delta g(y)^T] \\ &= \mathbb{E}[(x - \hat{x})(x - \hat{x})^T] + \mathbb{E}[\Delta g(y)\Delta g(y)^T] = \mathbb{E}[(x - \hat{x})(x - \hat{x})^T] + M \geq \mathbb{E}[(x - \hat{x})(x - \hat{x})^T] \end{aligned}$$

dove abbiamo usato il fatto che $\mathbb{E}_{x|y}[x|y] = \hat{g}(y)$ e $M \geq 0 \forall g(\cdot)$. Questo dimostra (1.1). Per dimostrare (1.2) si utilizzano le proprietà della traccia, definita in 1.3, come segue

$$\begin{aligned} \mathbb{E}[(x - \hat{x})(x - \hat{x})^T] &\leq \mathbb{E}[(x - \tilde{x}_g)(x - \tilde{x}_g)^T] \implies \mathbb{E}[Q(x - \hat{x})(x - \hat{x})^T] \leq \mathbb{E}[Q(x - \tilde{x}_g)(x - \tilde{x}_g)^T] \\ \implies (\text{tr}(\mathbb{E}[Q(x - \hat{x})(x - \hat{x})^T])) &\leq (\text{tr}(\mathbb{E}[Q(x - \tilde{x}_g)(x - \tilde{x}_g)^T])) \implies \mathbb{E}[\|x - \hat{x}\|_Q^2] \leq \mathbb{E}[\|x - \tilde{x}\|_Q^2] \end{aligned}$$

Passiamo ora a dimostrare l'incorrelazione tra lo stimatore e una qualsiasi funzione dei dati:

$$\begin{aligned} \mathbb{E}[e\hat{g}(y)^T] &= \mathbb{E}_{xy}[(x - \hat{x})\hat{g}(y)^T] = \mathbb{E}_y[\mathbb{E}_{x|y}[(x - \hat{x})\hat{g}(y)^T|y]] = \\ &= \mathbb{E}_y[(\mathbb{E}_{x|y}[x|y] - \hat{x})\hat{g}(y)^T] = \mathbb{E}_y[(\hat{x} - \hat{x})\hat{g}(y)^T] = 0 \end{aligned}$$

Infine dimostriamo che lo stimatore ottimo è corretto (unbiased):

$$\mathbb{E}[\hat{x}] = \mathbb{E}_y[\hat{x}] = \mathbb{E}_y[\mathbb{E}_{x|y}[x|y]] = \mathbb{E}_{xy}[x] = \mathbb{E}_x[x] = \mathbb{E}[x]$$

□

Questo teorema dimostra che lo stimatore ottimo in media quadratica coincide con l'aspettazione condizionata della variabile incognita x , rispetto ai dati misurati y . In genere lo stimatore ottimo è una funzione non-lineare dei dati e quindi di poca utilità pratica. Tuttavia, nel caso di processi gaussiani, lo stimatore ottimo si può calcolare in modo esplicito e risulta essere una funzione lineare¹ dei dati, come indicato nella Proposizione 1.2-2, in quanto $\hat{x} = \mu_{x|y}$. Il filtro di Kalman non è altro che un modo efficiente per calcolare l'aspettazione, condizionata rispetto ad una serie di misure, di una variabile aleatoria gaussiana.

1.2 Processi lineari stocastici e stimatori ottimi

Consideriamo ora un sistema lineare stocastico a tempo discreto del tipo:

$$x_{k+1} = Ax_k + w_k \quad (1.5)$$

$$y_k = Cx_k + v_k \quad (1.6)$$

dove $x_k \in \mathbb{R}^n, y_k \in \mathbb{R}^m, A \in \mathbb{R}^{n \times n}, C \in \mathbb{R}^{m \times n}$, e $w_k \sim \mathcal{N}(0, Q), v_k \sim \mathcal{N}(0, R)$ e $x_0 \sim \mathcal{N}(\bar{x}_0, P_0)$ sono variabili aleatorie gaussiane incorrelate² ed identicamente distribuite (i.i.d.), dove $Q \geq 0, R \geq 0, P_0 \geq 0$. Per semplificare la notazione abbiamo indicato $x_k = x(k)$ dove $k = 0, 1, 2, \dots$ sono gli istanti temporali. Definiamo anche le seguenti quantità:

$$\hat{x}_{k|h} = \mathbb{E}[x_k | y_0, \dots, y_k] \quad (1.7)$$

$$P_{k|h} = \mathbb{E}[(x_k - \hat{x}_{k|h})(x_k - \hat{x}_{k|h})^T | y_0, \dots, y_k] \quad (1.8)$$

¹Formalmente la funzione è *affine* anche se è uso comune usare impropriamente il termine *lineare*.

²Per semplicità non verrà trattato il caso di variabili aleatorie correlate e/o tempo varianti. E' possibile tuttavia generalizzare i risultati che seguono per tali variabili.

Lo stimatore $\hat{x}_{k|h}$ viene interpretato come un filtro $\hat{x}_{k|k}$ se $k = h + N$, un predittore a N passi $\hat{x}_{k+N|k}$ se $k = h + N$ e un interpolatore (*smoother*) a N passi $\hat{x}_{k|k+N}$ se $k = h - N$. La matrice semidefinita positiva $P_{k|h} \geq 0$ corrisponde invece alla varianza dell'errore di stima.

Prima di derivare le usuali equazioni del filtro di Kalman è interessante notare come in realtà i risultati descritti nella sezione precedente siano sufficienti per ottenere lo stimatore ottimo date le misure fino all'istante k . A questo scopo definiamo le nuove variabili aleatorie $\mathbf{x}_k = (x_k, x_{k-1}, \dots, x_1) \in \mathbb{R}^{kn}$, $\mathbf{y}_k = (y_k, y_{k-1}, \dots, y_1, y_0) \in \mathbb{R}^{(k+1)m}$, $\mathbf{v}_k = (v_k, v_{k-1}, \dots, v_1, v_0) \in \mathbb{R}^{(k+1)m}$ e $\mathbf{w}_k = (w_{k-1}, w_{k-2}, \dots, w_0) \in \mathbb{R}^{kn}$ per poter riscrivere la dinamica del sistema stocastico in maniera compatta come segue:

$$\mathbf{x}_k = \begin{pmatrix} I & A & A^2 & \dots & A^{k-1} \\ 0 & I & A & \dots & A^{k-2} \\ 0 & 0 & I & \dots & A^{k-3} \\ \vdots & & & & \vdots \\ 0 & 0 & 0 & \dots & I \end{pmatrix} \mathbf{w}_k + \begin{pmatrix} A^k \\ A^{k-1} \\ \vdots \\ A^2 \\ A \end{pmatrix} x_0 = F\mathbf{w}_k + Gx_0$$

$$\mathbf{y}_k = \begin{pmatrix} C & CA & CA^2 & \dots & CA^{k-1} \\ 0 & C & CA & \dots & CA^{k-2} \\ 0 & 0 & C & \dots & CA^{k-3} \\ \vdots & & & & \vdots \\ 0 & 0 & 0 & \dots & C \end{pmatrix} \mathbf{w}_k + \begin{pmatrix} CA^k \\ CA^{k-1} \\ \vdots \\ CA^2 \\ CA \end{pmatrix} x_0 + \mathbf{v}_k = H\mathbf{w}_k + Lx_0 + \mathbf{v}_k$$

Si vede chiaramente che $\mathbf{x}_k, \mathbf{y}_k$ sono variabili aleatorie gaussiane essendo combinazioni lineari di variabili aleatorie gaussiane. Da un punto di vista teorico è quindi facile ottenere lo stimatore ottimo \hat{x}_k calcolando medie e varianze congiunte delle variabili $\mathbf{x}_k, \mathbf{y}_k$ come indicato nella Proposizione 1.2-1 e poi calcolando la stima condizionata $\mathbb{E}[\mathbf{x}_k|\mathbf{y}_k]$ come indicato nella Proposizione 1.2-2. Lo stimatore ottimo \hat{x}_k è dato dai primi n elementi del vettore $\mathbb{E}[\mathbf{x}_k|\mathbf{y}_k]$. Si noti come implicitamente si sia calcolato anche l'interpolazione (*smoothing*) degli stati precedenti $\hat{x}_{h|k}$ per $h = 1, \dots, k - 1$.

Sebbene molto intuitivo e matematicamente compatto, il calcolo dello stimatore ottimo necessita l'inversione di matrici estremamente elevate, che crescono di dimensione all'aumentare di k . Tuttavia, come si può notare, le precedenti equazioni hanno una struttura particolare: quella più evidente è che alcune matrici sono triangolari inferiori. Le equazioni del filtro di Kalman sono un algoritmo ricorsivo numericamente efficiente che sfrutta appunto la particolare struttura del problema, riducendo i tempi e le difficoltà di computazione.

Bibliografia

- [1] Giorgio Picci. *Fitraggio Statistico (Wiener, Levinson, Kalman) e Applicazioni*. Libreria Progetto, 2006.