

Université de Rennes 1
DEA STIR
Signal — Télécommunications — Images — Radar
Option Signal

Examen du cours
“Filtre de Kalman et modèles de Markov cachés”
Jeudi 9 janvier 1997, 8:00 à 9:30
— Corrigé —

EXERCICE :

Soit $\{X_k\}$ une chaîne de Markov à espace d'état fini $E = \{1, \dots, N\}$, caractérisée par les données suivantes :

- loi initiale $\nu = (\nu_i)$

$$\nu_i = \mathbf{P}[X_0 = i] , \quad \text{pour tout } i \in E,$$

- matrice de transition $\pi = (\pi_{i,j})$

$$\pi_{i,j} = \mathbf{P}[X_{k+1} = j \mid X_k = i] , \quad \text{pour tout } i, j \in E.$$

Soit $\{Y_k\}$ une suite d'observations, telle que :

$$Y_k = h(X_k) + V_k ,$$

où la suite $\{V_k\}$ est un bruit blanc gaussien de dimension d , de moyenne nulle et de matrice de covariance identité, indépendant de la chaîne de Markov $\{X_k\}$. La fonction h définie sur E à valeurs dans \mathbf{R}^d est caractérisée par la donnée d'une famille $h = (h_i)$ de N vecteurs de \mathbf{R}^d , et on a

$$\psi_i(y) dy = \mathbf{P}[Y_k \in dy \mid X_k = i] = \frac{1}{(\sqrt{2\pi})^d} \exp \left\{ -\frac{1}{2} |y - h_i|^2 \right\} dy ,$$

pour tout $i \in E$, et tout $y \in \mathbf{R}^d$.

Le but de cet exercice est de proposer un algorithme d'estimation pour le vecteur des moyennes (h_i) .

On considère dans un premier temps le cas où $\{X_0, \dots, X_n\}$ et $\{Y_0, \dots, Y_n\}$ sont observés. La fonction de log-vraisemblance pour l'estimation de $h = (h_i)$, à partir de l'observation de $\{X_0, \dots, X_n\}$ et $\{Y_0, \dots, Y_n\}$, s'écrit

$$\ell(h) = -\frac{1}{2} \sum_{k=0}^n |Y_k - h(X_k)|^2 .$$

(i) **En utilisant la décomposition**

$$h(X_k) = \sum_{i \in E} h_i \mathbf{1}_{[X_k = i]} ,$$

montrer que

$$\ell(h) = -\frac{1}{2} \sum_{i \in E} \sum_{k=0}^n \mathbf{1}_{[X_k = i]} |Y_k - h_i|^2 .$$

SOLUTION

Par définition

$$\begin{aligned} \ell(h) &= -\frac{1}{2} \sum_{k=0}^n |Y_k - h(X_k)|^2 \\ &= -\frac{1}{2} \sum_{k=0}^n \sum_{i \in E} \mathbf{1}_{[X_k = i]} |Y_k - h(X_k)|^2 \\ &= -\frac{1}{2} \sum_{i \in E} \sum_{k=0}^n \mathbf{1}_{[X_k = i]} |Y_k - h_i|^2 . \end{aligned}$$

□

(ii) **En maximisant $\ell(h)$ par rapport au vecteur h_i , montrer que l'estimateur du maximum de vraisemblance pour la moyenne h_i , à partir de l'observation de $\{X_0, \dots, X_n\}$ et $\{Y_0, \dots, Y_n\}$, est donné par**

$$\hat{h}_i = \frac{\sum_{k=0}^n Y_k \mathbf{1}_{[X_k = i]}}{\sum_{k=0}^n \mathbf{1}_{[X_k = i]}} .$$

SOLUTION

Le vecteur \widehat{h}_i maximise l'application

$$h_i \longmapsto -\frac{1}{2} \sum_{k=0}^n \mathbf{1}_{[X_k = i]} |Y_k - h_i|^2 .$$

Il vérifie l'équation

$$\sum_{k=0}^n \mathbf{1}_{[X_k = i]} (Y_k - h_i) = 0 ,$$

ou de façon équivalente

$$h_i \sum_{k=0}^n \mathbf{1}_{[X_k = i]} = \sum_{k=0}^n Y_k \mathbf{1}_{[X_k = i]} ,$$

c'est-à-dire que

$$\widehat{h}_i = \frac{\sum_{k=0}^n Y_k \mathbf{1}_{[X_k = i]}}{\sum_{k=0}^n \mathbf{1}_{[X_k = i]}} .$$

□

On considère ensuite le cas où seulement $\{Y_0, \dots, Y_n\}$ est observé. On pose

$$N_i = \sum_{k=0}^n \mathbf{1}_{[X_k = i]} \quad \text{et} \quad O_i = \sum_{k=0}^n Y_k \mathbf{1}_{[X_k = i]} .$$

(iii) **En supposant le modèle $\mathbf{M} = (\nu, \pi, h)$ connu, donner l'expression des estimateurs $\widehat{N}_i = \mathbf{E}[N_i | \mathcal{Y}_n]$ et $\widehat{O}_i = \mathbf{E}[O_i | \mathcal{Y}_n]$ à l'aide des variables forward et backward correspondantes.**

SOLUTION

On a

$$\widehat{N}_i = \mathbf{E}[N_i | \mathcal{Y}_n] = \sum_{k=0}^n \mathbf{P}[X_k = i | \mathcal{Y}_n] = \frac{1}{P} \sum_{k=0}^n q_k^i ,$$

où $q_k^i = p_k^i v_k^i$ pour tout $i \in E$, et pour tout instant $k = 0, \dots, n$, et où la constante de normalisation

$$P = \sum_{j \in E} q_k^j ,$$

ne dépend pas de l'instant $k = 0, \dots, n$.

De même

$$\widehat{O}_i = \mathbf{E}[O_i | \mathcal{Y}_n] = \sum_{k=0}^n \mathbf{E}[Y_k \mathbf{1}_{[X_k = i]} | \mathcal{Y}_n] = \sum_{k=0}^n Y_k \mathbf{P}[X_k = i | \mathcal{Y}_n] = \frac{1}{P} \sum_{k=0}^n Y_k q_k^i .$$

□

(iv) Proposer un algorithme itératif pour l'estimation de la moyenne h_i à partir de l'observation de $\{Y_0, \dots, Y_n\}$ seulement.

SOLUTION

On peut proposer l'algorithme itératif suivant, qui repose sur la notion de re-estimation.

initialisation : choix initial h .

étape E : résolution des équations forward-backward de Baum, pour le modèle $\mathbf{M} = (\nu, \pi, h)$

$$p_{k+1}^j = \psi_j(Y_{k+1}) \sum_{i \in E} \pi_{i,j} p_k^i, \quad p_0^i = \nu^i,$$

$$v_k^i = \sum_{j \in E} \left[\pi_{i,j} \psi_j(Y_{k+1}) v_{k+1}^j \right], \quad v_n^i = 1,$$

où on a défini

$$\psi_i(y) = \frac{1}{(\sqrt{2\pi})^d} \exp \left\{ -\frac{1}{2} |y - h_i|^2 \right\},$$

pour tout $i \in E$, et pour tout $y \in \mathbf{R}^d$.

étape M : re-estimation du vecteur des moyennes

$$\hat{h}_i = \frac{\hat{O}_i}{\hat{N}_i} = \frac{\sum_{k=0}^n Y_k q_k^i}{\sum_{k=0}^n q_k^i}.$$

itération : $h = \hat{h}$, et retour à l'étape E.

□

PROBLÈME :

Le but de ce problème est d'établir les équations de l'estimateur du maximum a posteriori dans le cas linéaire gaussien, et de montrer que cet estimateur coïncide avec le filtre de Kalman.

On considère le système linéaire suivant :

$$X_{k+1} = F X_k + W_k , \quad (\text{dans } \mathbf{R}^m)$$

$$Y_k = H X_k + V_k , \quad (\text{dans } \mathbf{R}^d)$$

avec les hypothèses habituelles :

- X_0 variable aléatoire gaussienne, de moyenne μ_0 et de matrice de covariance Σ_0 .
- $\{W_k\}$ bruit blanc gaussien centré de matrice de covariance Q .
- $\{V_k\}$ bruit blanc gaussien centré de matrice de covariance R inversible.
- $X_0, \{W_k\}$ et $\{V_k\}$ mutuellement indépendants.

Pour simplifier la dérivation, on suppose en outre que les matrices de covariance Σ_0 et Q sont *inversibles*.

- (i) **Montrer que la loi conditionnelle de X_k sachant (X_0, \dots, X_{k-1}) est donnée par**

$$\begin{aligned} & \mathbf{P}[X_k \in dx \mid X_0 = x_0, \dots, X_{k-1} = x_{k-1}] = \\ & = \frac{1}{(\sqrt{2\pi})^m \sqrt{\det Q}} \exp \left\{ -\frac{1}{2} (x - F x_{k-1})^* Q^{-1} (x - F x_{k-1}) \right\} dx . \end{aligned}$$

En déduire que la suite $\{X_k\}$ est une chaîne de Markov à valeur dans \mathbf{R}^m .

SOLUTION

Par définition

$$X_k = F X_{k-1} + W_{k-1} ,$$

et on remarque que (X_0, \dots, X_{k-1}) ne dépend que de $(X_0, W_0, \dots, W_{k-2})$. Il en résulte que :

- le vecteur aléatoire X_{k-1} dépend de (X_0, \dots, X_{k-1}) ,
- et le vecteur aléatoire W_{k-1} est indépendant de (X_0, \dots, X_{k-1}) .

On peut donc dire que *la connaissance de (X_0, \dots, X_{k-1}) n'apprend rien de plus sur X_k que la connaissance de X_{k-1} seulement.*

Il en résulte que la suite $\{X_k\}$ est une chaîne de Markov à valeurs dans \mathbf{R}^m .

Conditionnellement à $(X_{k-1} = x_{k-1})$, le vecteur aléatoire X_k est un vecteur aléatoire gaussien de \mathbf{R}^m , de moyenne $F x_{k-1}$ et de matrice de covariance Q , d'où la loi conditionnelle

$$\begin{aligned} \mathbf{P}[X_k \in dx \mid X_0 = x_0, \dots, X_{k-1} = x_{k-1}] &= \mathbf{P}[X_k \in dx \mid X_{k-1} = x_{k-1}] = \\ &= \frac{1}{(\sqrt{2\pi})^m \sqrt{\det Q}} \exp \left\{ -\frac{1}{2} (x - F x_{k-1})^* Q^{-1} (x - F x_{k-1}) \right\} dx . \end{aligned}$$

□

(ii) **Déduire de (i) que la loi jointe de (X_0, \dots, X_n) est donnée par**

$$\begin{aligned} \mathbf{P}[X_0 \in dx_0, \dots, X_n \in dx_n] &= \\ &= \frac{1}{(\sqrt{2\pi})^m \sqrt{\det \Sigma_0}} \left[\frac{1}{(\sqrt{2\pi})^m \sqrt{\det Q}} \right]^n \\ &\quad \exp \left\{ -\frac{1}{2} (x_0 - \mu_0)^* \Sigma_0^{-1} (x_0 - \mu_0) - \frac{1}{2} \sum_{k=1}^n (x_k - F x_{k-1})^* Q^{-1} (x_k - F x_{k-1}) \right\} \\ &\quad dx_0 dx_1 \cdots dx_n . \end{aligned}$$

SOLUTION

La loi jointe de (X_0, \dots, X_n) est obtenue par application répétée de la formule de Bayes

$$\begin{aligned} \mathbf{P}[X_0 \in dx_0, \dots, X_n \in dx_n] &= \\ &= \mathbf{P}[X_n \in dx_n \mid X_0 = x_0, \dots, X_{n-1} = x_{n-1}] \mathbf{P}[X_0 \in dx_0, \dots, X_{n-1} \in dx_{n-1}] \\ &= \prod_{k=1}^n \mathbf{P}[X_k \in dx_k \mid X_0 = x_0, \dots, X_{k-1} = x_{k-1}] \mathbf{P}[X_0 \in dx_0] , \end{aligned}$$

ce qui donne d'après (i)

$$\begin{aligned} \mathbf{P}[X_0 \in dx_0, \dots, X_n \in dx_n] &= \\ &= \frac{1}{(\sqrt{2\pi})^m \sqrt{\det \Sigma_0}} \left[\frac{1}{(\sqrt{2\pi})^m \sqrt{\det Q}} \right]^n \\ &\quad \exp \left\{ -\frac{1}{2} (x_0 - \mu_0)^* \Sigma_0^{-1} (x_0 - \mu_0) - \frac{1}{2} \sum_{k=1}^n (x_k - F x_{k-1})^* Q^{-1} (x_k - F x_{k-1}) \right\} \\ &\quad dx_0 dx_1 \cdots dx_n . \end{aligned}$$

□

(iii) **Montrer que la propriété de canal sans mémoire est vérifiée, et que**

$$\mathbf{P}[Y_k \in dy \mid X_k = x] = \frac{1}{(\sqrt{2\pi})^d \sqrt{\det R}} \exp \left\{ -\frac{1}{2} (y - Hx)^* R^{-1} (y - Hx) \right\} dy .$$

SOLUTION

Par définition

$$\begin{pmatrix} Y_0 \\ \vdots \\ Y_k \end{pmatrix} = \begin{pmatrix} H & 0 & \cdots & \cdots & 0 \\ 0 & H & 0 & & \vdots \\ \vdots & \ddots & \ddots & \ddots & \vdots \\ \vdots & & 0 & H & 0 \\ 0 & \cdots & \cdots & 0 & H \end{pmatrix} \begin{pmatrix} X_0 \\ \vdots \\ X_k \end{pmatrix} + \begin{pmatrix} V_0 \\ \vdots \\ V_k \end{pmatrix} ,$$

et par hypothèse (V_0, \dots, V_k) est indépendant de (X_0, \dots, X_k) . Il en résulte que, conditionnellement à (X_0, \dots, X_k) les vecteurs aléatoires Y_0, \dots, Y_k sont des vecteurs aléatoires gaussiens de \mathbf{R}^d mutuellement indépendants. En outre

$$Y_l = H X_l + V_l ,$$

pour tout $l = 0, \dots, k$, et le vecteur aléatoire V_l est indépendant de (X_0, \dots, X_k) . On peut donc dire que *la connaissance de (X_0, \dots, X_k) n'apprend rien de plus sur Y_l que la connaissance de X_l seulement.*

Il résulte de ces deux remarques que la propriété de canal sans mémoire est vérifiée.

En particulier, conditionnellement à $(X_k = x)$, le vecteur aléatoire Y_k est un vecteur aléatoire gaussien de moyenne Hx et de matrice de covariance R , d'où la loi conditionnelle

$$\mathbf{P}[Y_k \in dy \mid X_k = x] = \frac{1}{(\sqrt{2\pi})^d \sqrt{\det R}} \exp \left\{ -\frac{1}{2} (y - Hx)^* R^{-1} (y - Hx) \right\} dy .$$

□

(iv) **Déduire de (ii) et (iii) que la loi jointe de $(X_0, \dots, X_n, Y_0, \dots, Y_n)$ est donnée par**

$$\begin{aligned} & \mathbf{P}[X_0 \in dx_0, \dots, X_n \in dx_n, Y_0 \in dy_0, \dots, Y_n \in dy_n] = \\ & = \frac{1}{(\sqrt{2\pi})^m \sqrt{\det \Sigma_0}} \left[\frac{1}{(\sqrt{2\pi})^m \sqrt{\det Q}} \right]^n \left[\frac{1}{(\sqrt{2\pi})^d \sqrt{\det R}} \right]^{n+1} \\ & \quad \exp \left\{ -\frac{1}{2} (x_0 - \mu_0)^* \Sigma_0^{-1} (x_0 - \mu_0) - \frac{1}{2} \sum_{k=1}^n (x_k - F x_{k-1})^* Q^{-1} (x_k - F x_{k-1}) \right. \\ & \quad \left. - \frac{1}{2} \sum_{k=0}^n (y_k - H x_k)^* R^{-1} (y_k - H x_k) \right\} \\ & \quad dx_0 dx_1 \cdots dx_n dy_0 dy_1 \cdots dy_n . \end{aligned}$$

SOLUTION

La loi jointe de $(X_0, \dots, X_n, Y_0, \dots, Y_n)$ est obtenue par application de la formule de Bayes

$$\begin{aligned} \mathbf{P}[X_0 \in dx_0, \dots, X_n \in dx_n, Y_0 \in dy_0, \dots, Y_n \in dy_n] &= \\ &= \mathbf{P}[Y_0 \in dy_0, \dots, Y_n \in dy_n \mid X_0 = x_0, \dots, X_n = x_n] \mathbf{P}[X_0 \in dx_0, \dots, X_n \in dx_n] . \end{aligned}$$

D'après la propriété de canal sans mémoire, et d'après l'expression obtenue en (iii), la loi de (Y_0, \dots, Y_n) sachant (X_0, \dots, X_n) est donnée par

$$\begin{aligned} \mathbf{P}[Y_0 \in dy_0, \dots, Y_n \in dy_n \mid X_0 = x_0, \dots, X_n = x_n] &= \prod_{k=0}^n \mathbf{P}[Y_k \in dy_k \mid X_k = x_k] = \\ &= \left[\frac{1}{(\sqrt{2\pi})^d \sqrt{\det R}} \right]^{n+1} \exp \left\{ -\frac{1}{2} \sum_{k=0}^n (y_k - H x_k)^* R^{-1} (y_k - H x_k) \right\} dy_0 dy_1 \dots dy_n . \end{aligned}$$

On obtient le résultat demandé en utilisant l'expression de la loi jointe de (X_0, \dots, X_n) obtenue en (ii). □

Par définition, l'estimateur du maximum a posteriori pour la suite $\{X_0, \dots, X_n\}$ est la suite d'états (x_0, \dots, x_n) qui maximise la densité conditionnelle de (X_0, \dots, X_n) sachant (Y_0, \dots, Y_n) .

- (v) **Montrer que maximiser par rapport à (x_0, \dots, x_n) la densité conditionnelle de (X_0, \dots, X_n) sachant (Y_0, \dots, Y_n) donne le même résultat que maximiser par rapport à (x_0, \dots, x_n) la densité jointe de $(X_0, \dots, X_n, Y_0, \dots, Y_n)$.**

SOLUTION

Par définition

$$\begin{aligned} p_{X_0, \dots, X_n \mid Y_0=y_0, \dots, Y_n=y_n}(x_0, \dots, x_n) p_{Y_0, \dots, Y_n}(y_0, \dots, y_n) &= \\ &= p_{X_0, \dots, X_n, Y_0, \dots, Y_n}(x_0, \dots, x_n, y_0, \dots, y_n) . \end{aligned}$$

La densité conditionnelle de (X_0, \dots, X_n) sachant (Y_0, \dots, Y_n) et la densité jointe de $(X_0, \dots, X_n, Y_0, \dots, Y_n)$ ne diffèrent donc que par une constante multiplicative qui ne dépend que de (y_0, \dots, y_n) , d'où le résultat. □

On se propose donc de minimiser par rapport à (x_0, \dots, x_n) la fonction suivante

$$\begin{aligned} J_n(x_0, \dots, x_n) &= \frac{1}{2} (x_0 - \mu_0)^* \Sigma_0^{-1} (x_0 - \mu_0) \\ &\quad + \frac{1}{2} \sum_{k=1}^n (x_k - F x_{k-1})^* Q^{-1} (x_k - F x_{k-1}) \\ &\quad + \frac{1}{2} \sum_{k=0}^n (Y_k - H x_k)^* R^{-1} (Y_k - H x_k) . \end{aligned}$$

On définit

$$V_n(x) = \min_{x_0, \dots, x_{n-1}} J_n(x_0, \dots, x_{n-1}, x) .$$

L'objectif de la fin du problème est de montrer par récurrence que

$$V_n(x) = \frac{1}{2} (x - \mu_n)^* \Sigma_n^{-1} (x - \mu_n) + c_n , \quad (\star)$$

et de caractériser la matrice Σ_n , le vecteur μ_n , et le scalaire c_n .

(vi) **Déduire de (\star) que μ_n est l'estimateur du maximum a posteriori pour l'état X_n .**

SOLUTION

Pour tout $x \in \mathbf{R}^m$

$$V_n(x) = \min_{x_0, \dots, x_{n-1}} J_n(x_0, \dots, x_{n-1}, x) = J_n(\xi_0(x), \dots, \xi_{n-1}(x), x) ,$$

pour une certaine suite $(\xi_0(x), \dots, \xi_{n-1}(x))$ qui dépend de x . D'autre part

$$\min_x V_n(x) = \min_{x_0, \dots, x_n} J_n(x_0, \dots, x_n) = J_n(X_0^{\text{MAP}}, \dots, X_n^{\text{MAP}}) ,$$

où par définition la suite $(X_0^{\text{MAP}}, \dots, X_n^{\text{MAP}})$ est appelée *estimateur du maximum a posteriori* de la suite (X_0, \dots, X_n) .

D'après la formule de récurrence (\star) , le minimum de l'application V_n est atteint pour $x = \mu_n$, c'est-à-dire que

$$J_n(X_0^{\text{MAP}}, \dots, X_n^{\text{MAP}}) = V_n(\mu_n) = J_n(\xi_0(\mu_n), \dots, \xi_{n-1}(\mu_n), \mu_n) .$$

On en déduit que

$$(X_0^{\text{MAP}}, \dots, X_n^{\text{MAP}}) = (\xi_0(\mu_n), \dots, \xi_{n-1}(\mu_n), \mu_n) ,$$

pourvu que le minimum de l'application J_n soit unique. En particulier

$$X_n^{\text{MAP}} = \mu_n .$$

□

(vii) **Montrer que**

$$J_{k+1}(x_0, \dots, x_k, x) = J_k(x_0, \dots, x_k) + \frac{1}{2} (x - F x_k)^* Q^{-1} (x - F x_k) \\ + \frac{1}{2} (Y_{k+1} - H x)^* R^{-1} (Y_{k+1} - H x) .$$

SOLUTION

Par définition

$$J_{k+1}(x_0, \dots, x_k, x) = \\ = \frac{1}{2} (x_0 - \mu_0)^* \Sigma_0^{-1} (x_0 - \mu_0) + \frac{1}{2} \sum_{l=1}^k (x_l - F x_{l-1})^* Q^{-1} (x_l - F x_{l-1}) \\ + \frac{1}{2} (x - F x_k)^* Q^{-1} (x - F x_k) \\ + \frac{1}{2} \sum_{l=0}^k (Y_l - H x_l)^* R^{-1} (Y_l - H x_l) + \frac{1}{2} (Y_{k+1} - H x)^* R^{-1} (Y_{k+1} - H x) \\ = J_k(x_0, \dots, x_k) + \frac{1}{2} (x - F x_k)^* Q^{-1} (x - F x_k) \\ + \frac{1}{2} (Y_{k+1} - H x)^* R^{-1} (Y_{k+1} - H x) .$$

□

(viii) **En prenant le minimum par rapport à (x_0, \dots, x_k) et en utilisant l'hypothèse de récurrence (\star) supposée vraie à l'instant k , montrer que**

$$V_{k+1}(x) = \min_{x_k} \left[\frac{1}{2} (x_k - \mu_k)^* \Sigma_k^{-1} (x_k - \mu_k) + \frac{1}{2} (x - F x_k)^* Q^{-1} (x - F x_k) \right] \\ + \frac{1}{2} (Y_{k+1} - H x)^* R^{-1} (Y_{k+1} - H x) + c_k .$$

SOLUTION

D'après (vii)

$$V_{k+1}(x) = \min_{x_0, \dots, x_k} J_{k+1}(x_0, \dots, x_k, x) \\ = \min_{x_0, \dots, x_k} \left[J_k(x_0, \dots, x_k) + \frac{1}{2} (x - F x_k)^* Q^{-1} (x - F x_k) \right] \\ + \frac{1}{2} (Y_{k+1} - H x)^* R^{-1} (Y_{k+1} - H x)$$

$$\begin{aligned}
&= \min_{x_k} \left[\min_{x_0, \dots, x_{k-1}} J_k(x_0, \dots, x_k) + \frac{1}{2} (x - F x_k)^* Q^{-1} (x - F x_k) \right] \\
&\quad + \frac{1}{2} (Y_{k+1} - H x)^* R^{-1} (Y_{k+1} - H x) \\
&= \min_{x_k} \left[V_k(x_k) + \frac{1}{2} (x - F x_k)^* Q^{-1} (x - F x_k) \right] \\
&\quad + \frac{1}{2} (Y_{k+1} - H x)^* R^{-1} (Y_{k+1} - H x) ,
\end{aligned}$$

et d'après l'hypothèse de récurrence (\star)

$$\begin{aligned}
V_{k+1}(x) &= \min_{x_k} \left[\frac{1}{2} (x_k - \mu_k)^* \Sigma_k^{-1} (x_k - \mu_k) + c_k + \frac{1}{2} (x - F x_k)^* Q^{-1} (x - F x_k) \right] \\
&\quad + \frac{1}{2} (Y_{k+1} - H x)^* R^{-1} (Y_{k+1} - H x) .
\end{aligned}$$

□

(ix) **Effectuer la minimisation par rapport à x_k , et montrer que**

$$\begin{aligned}
V_{k+1}(x) &= \frac{1}{2} (x - F \mu_k)^* (F \Sigma_k F^* + Q)^{-1} (x - F \mu_k) \\
&\quad + \frac{1}{2} (Y_{k+1} - H x)^* R^{-1} (Y_{k+1} - H x) + c_k .
\end{aligned}$$

SOLUTION

On commence par développer, et par compléter le carré, de la façon suivante

$$\begin{aligned}
&\frac{1}{2} (x_k - \mu_k)^* \Sigma_k^{-1} (x_k - \mu_k) + \frac{1}{2} (x - F x_k)^* Q^{-1} (x - F x_k) = \\
&= \frac{1}{2} x_k^* (\Sigma_k^{-1} + F^* Q^{-1} F) x_k - x_k^* (\Sigma_k^{-1} \mu_k + F^* Q^{-1} x) + \frac{1}{2} (\mu_k^* \Sigma_k^{-1} \mu_k + x^* Q^{-1} x) \\
&= \frac{1}{2} x_k^* A x_k - x_k^* b + \frac{1}{2} e \\
&= \frac{1}{2} (x_k - A^{-1} b)^* A (x_k - A^{-1} b) + \frac{1}{2} e - \frac{1}{2} b^* A^{-1} b ,
\end{aligned}$$

avec

$$A = \Sigma_k^{-1} + F^* Q^{-1} F , \quad b = \Sigma_k^{-1} \mu_k + F^* Q^{-1} x , \quad e = \mu_k^* \Sigma_k^{-1} \mu_k + x^* Q^{-1} x .$$

On en déduit d'abord que

$$\min_{x_k} \left[\frac{1}{2} (x_k - \mu_k)^* \Sigma_k^{-1} (x_k - \mu_k) + \frac{1}{2} (x - F x_k)^* Q^{-1} (x - F x_k) \right] = \frac{1}{2} e - \frac{1}{2} b^* A^{-1} b .$$

On remarque ensuite, d'après le Lemme 1.1 du cours, que

$$A^{-1} = (\Sigma_k^{-1} + F^* Q^{-1} F)^{-1} = \Sigma_k - \Sigma_k F^* (F \Sigma_k F^* + Q)^{-1} F \Sigma_k ,$$

d'où

$$\begin{aligned} A^{-1} b &= [\Sigma_k - \Sigma_k F^* (F \Sigma_k F^* + Q)^{-1} F \Sigma_k] (\Sigma_k^{-1} \mu_k + F^* Q^{-1} x) \\ &= \mu_k + \Sigma_k F^* Q^{-1} x - \Sigma_k F^* (F \Sigma_k F^* + Q)^{-1} F \mu_k \\ &\quad - \Sigma_k F^* (F \Sigma_k F^* + Q)^{-1} F \Sigma_k F^* Q^{-1} x \\ &= \mu_k + \Sigma_k F^* (F \Sigma_k F^* + Q)^{-1} (x - F \mu_k) , \end{aligned}$$

et finalement

$$\begin{aligned} b^* A^{-1} b &= (\mu_k^* \Sigma_k^{-1} + x^* Q^{-1} F) [\mu_k + \Sigma_k F^* (F \Sigma_k F^* + Q)^{-1} (x - F \mu_k)] \\ &= \mu_k^* \Sigma_k^{-1} \mu_k + \mu_k^* F^* (F \Sigma_k F^* + Q)^{-1} (x - F \mu_k) \\ &\quad + x^* Q^{-1} F \mu_k + x^* Q^{-1} F \Sigma_k F^* (F \Sigma_k F^* + Q)^{-1} (x - F \mu_k) \\ &= \mu_k^* \Sigma_k^{-1} \mu_k + x^* Q^{-1} x - (x - F \mu_k)^* (F \Sigma_k F^* + Q)^{-1} (x - F \mu_k) . \end{aligned}$$

On en déduit que

$$e - b^* A^{-1} b = (x - F \mu_k)^* (F \Sigma_k F^* + Q)^{-1} (x - F \mu_k) ,$$

et finalement

$$\begin{aligned} V_{k+1}(x) &= \frac{1}{2} (x - F \mu_k)^* (F \Sigma_k F^* + Q)^{-1} (x - F \mu_k) \\ &\quad + \frac{1}{2} (Y_{k+1} - H x)^* R^{-1} (Y_{k+1} - H x) + c_k . \end{aligned}$$

□

On introduit les notations suivantes :

$$\mu_{k+1}^- = F \mu_k \quad \text{et} \quad \Sigma_{k+1}^- = F \Sigma_k F^* + Q ,$$

ce qui donne

$$\begin{aligned} V_{k+1}(x) &= \frac{1}{2} (x - \mu_{k+1}^-)^* (\Sigma_{k+1}^-)^{-1} (x - \mu_{k+1}^-) \\ &\quad + \frac{1}{2} (Y_{k+1} - H x)^* R^{-1} (Y_{k+1} - H x) + c_k . \end{aligned}$$

(x) **Montrer que**

$$V_{k+1}(x) = \frac{1}{2} (x - \mu_{k+1})^* \Sigma_{k+1}^{-1} (x - \mu_{k+1}) + c_{k+1} ,$$

c'est-à-dire que la propriété (\star) est vérifiée, avec en particulier

$$\mu_{k+1} = \mu_{k+1}^- + \Sigma_{k+1}^- H^* (H \Sigma_{k+1}^- H^* + R)^{-1} (Y_{k+1} - H \mu_{k+1}^-) .$$

Comparer ces équations avec celles du filtre de Kalman, et conclure.

SOLUTION

On développe, et on complète le carré, de la façon suivante

$$\begin{aligned} V_{k+1}(x) &= \frac{1}{2} (x - \mu_{k+1}^-)^* (\Sigma_{k+1}^-)^{-1} (x - \mu_{k+1}^-) \\ &\quad + \frac{1}{2} (Y_{k+1} - H x)^* R^{-1} (Y_{k+1} - H x) + c_k \\ &= \frac{1}{2} x^* [(\Sigma_{k+1}^-)^{-1} + H^* R^{-1} H] x - x^* [(\Sigma_{k+1}^-)^{-1} \mu_{k+1}^- + H^* R^{-1} Y_{k+1}] \\ &\quad + \frac{1}{2} [(\mu_{k+1}^-)^* (\Sigma_{k+1}^-)^{-1} \mu_{k+1}^- + Y_{k+1}^* R^{-1} Y_{k+1}] + c_k \\ &= \frac{1}{2} x^* A x - x^* b + \frac{1}{2} e + c_k \\ &= \frac{1}{2} (x - A^{-1} b)^* A (x - A^{-1} b) + \frac{1}{2} e - \frac{1}{2} b^* A^{-1} b + c_k , \end{aligned}$$

avec

$$A = (\Sigma_{k+1}^-)^{-1} + H^* R^{-1} H , \quad b = (\Sigma_{k+1}^-)^{-1} \mu_{k+1}^- + H^* R^{-1} Y_{k+1} ,$$

$$e = (\mu_{k+1}^-)^* (\Sigma_{k+1}^-)^{-1} \mu_{k+1}^- + Y_{k+1}^* R^{-1} Y_{k+1} .$$

On en déduit que

$$V_{k+1}(x) = \frac{1}{2} (x - \mu_{k+1})^* \Sigma_{k+1}^{-1} (x - \mu_{k+1}) + c_{k+1} ,$$

avec

$$\Sigma_{k+1} = A^{-1} , \quad \mu_{k+1} = A^{-1} b , \quad c_{k+1} = \frac{1}{2} e - \frac{1}{2} b^* A^{-1} b + c_k ,$$

c'est-à-dire que l'hypothèse de récurrence (\star) est vérifiée.

On remarque ensuite, d'après le Lemme 1.1 du cours, que

$$\begin{aligned} \Sigma_{k+1} &= A^{-1} = [(\Sigma_{k+1}^-)^{-1} + H^* R^{-1} H]^{-1} \\ &= \Sigma_{k+1}^- - \Sigma_{k+1}^- H^* (H \Sigma_{k+1}^- H^* + R)^{-1} H \Sigma_{k+1}^- , \end{aligned}$$

d'où

$$\begin{aligned}
\mu_{k+1} = A^{-1} b &= [\Sigma_{k+1}^- - \Sigma_{k+1}^- H^* (H \Sigma_{k+1}^- H^* + R)^{-1} H \Sigma_{k+1}^-] \\
&\quad [(\Sigma_{k+1}^-)^{-1} \mu_{k+1}^- + H^* R^{-1} Y_{k+1}] \\
&= \mu_{k+1}^- + \Sigma_{k+1}^- H^* R^{-1} Y_{k+1} - \Sigma_{k+1}^- H^* (H \Sigma_{k+1}^- H^* + R)^{-1} H \mu_{k+1}^- \\
&\quad - \Sigma_{k+1}^- H^* (H \Sigma_{k+1}^- H^* + R)^{-1} H \Sigma_{k+1}^- H^* R^{-1} Y_{k+1} \\
&= \mu_{k+1}^- + \Sigma_{k+1}^- H^* (H \Sigma_{k+1}^- H^* + R)^{-1} (Y_{k+1} - H \mu_{k+1}^-) .
\end{aligned}$$

On reconnait les équations du filtre de Kalman.

□