

Université de Rennes 1
Master recherche STI
Examen du cours UE 14
“Filtre de Kalman et modèles de Markov cachés”
Jeudi 25 janvier 2007, 10:30 à 12:30
— Corrigé —

PROBLÈME

L’objectif de ce problème est d’étudier un algorithme récemment apparu en apprentissage automatique sous le nom d’*estimation bayésienne variationnelle*, pour estimer récursivement un paramètre inconnu dans un modèle à variables cachées. On se place dans le cadre de l’estimation bayésienne, c’est-à-dire que le paramètre inconnu est supposé aléatoire, et l’incertitude sur la valeur de ce paramètre est décrite par une distribution de probabilité *a priori*, supposée connue.

Soit X et Y deux vecteurs aléatoires, de dimension m et d respectivement. Comme d’habitude, la composante X est cachée et on observe seulement la composante Y . On suppose connue, à un paramètre inconnu A près, la densité de probabilité conjointe du couple (X, Y) , notée $p_{X,Y|A=a}(x, y)$. Le paramètre inconnu est considéré comme une variable aléatoire de dimension s , et on se donne sa densité de probabilité $p_A(a)$.

- (i) **Donner l’expression de la densité de probabilité conjointe du triplet (X, A, Y) , et montrer que la densité de probabilité marginale du vecteur aléatoire Y s’écrit**

$$p_Y(y) = \int_{\mathbb{R}^m} \int_{\mathbb{R}^s} dx da p_{X,Y|A=a}(x, y) p_A(a) .$$

SOLUTION

D’après la formule de Bayes

$$p_{X,A,Y}(x, a, y) = p_{X,Y|A=a}(x, y) p_A(a) ,$$

et en intégrant par rapport aux variables x et a , il vient

$$p_Y(y) = \int_{\mathbb{R}^m} \int_{\mathbb{R}^s} dx da p_{X,A,Y}(x, a, y) = \int_{\mathbb{R}^m} \int_{\mathbb{R}^s} dx da p_{X,Y|A=a}(x, y) p_A(a) .$$

□

On veut calculer la densité de probabilité *a posteriori* du paramètre, c'est-à-dire la densité de probabilité conditionnelle, notée $p_{A|Y=y}(a)$, du vecteur aléatoire A sachant l'observation Y . A cet effet, il suffit de calculer la densité de probabilité jointe *a posteriori* de l'état caché et du paramètre, c'est-à-dire la densité de probabilité conditionnelle jointe, notée $p_{X,A|Y=y}(x, a)$, du vecteur aléatoire (X, A) sachant l'observation Y .

(ii) Soit $q(x, a)$ une densité de probabilité arbitraire sur $\mathbb{R}^m \times \mathbb{R}^s$. Montrer que

$$\log p_Y(y) \geq \int_{\mathbb{R}^m} \int_{\mathbb{R}^s} dx da q(x, a) \log \frac{p_{X,Y|A=a}(x, y) p_A(a)}{q(x, a)} .$$

Indication : on utilisera l'inégalité de Jensen suivante

$$\mathbb{E}[\Phi(Z)] \leq \Phi(\mathbb{E}[Z]) ,$$

valable pour toute variable aléatoire Z et pour toute fonction concave Φ (par exemple $z \mapsto \log z$).

REMARQUE PRÉLIMINAIRE

La solution à la plupart des questions de ce problème découle des observations suivantes, qui sont de simples conséquences de l'inégalité de Jensen.

Si la variable aléatoire Z est de la forme $Z = \frac{f(W)}{q(W)}$, où

- la variable aléatoire W à valeurs dans E a pour densité de probabilité $q(w)$,
- la fonction positive $f(w)$ définie sur E s'annule en tout point w où la densité de probabilité $q(w)$ s'annule aussi,

alors l'inégalité de Jensen donne

$$\int_E dw q(w) \Phi\left(\frac{f(w)}{q(w)}\right) = \mathbb{E}[\Phi(Z)] \leq \Phi(\mathbb{E}[Z]) = \Phi\left(\int_E dw q(w) \frac{f(w)}{q(w)}\right) = \Phi\left(\int_E dw f(w)\right) ,$$

et en particulier pour la fonction concave $z \mapsto \log z$

$$\int_E dw q(w) \log \frac{f(w)}{q(w)} \leq \log \int_E dw f(w) .$$

En outre, on remarque que la densité de probabilité $q^*(w)$ définie par

$$q^*(w) = \frac{f(w)}{\int_E dw f(w)} ,$$

vérifie l'égalité

$$\int_E dw q^*(w) \log \frac{f(w)}{q^*(w)} = \log \int_E dw f(w) ,$$

c'est-à-dire que la borne supérieure

$$\int_E dw q(w) \log \frac{f(w)}{q(w)} \leq \log \int_E dw f(w) ,$$

valable pour toute densité de probabilité $q(w)$ ne s'annulant qu'aux points w où la fonction $f(w)$ s'annule aussi, est atteinte pour la densité de probabilité $q^*(w)$. On peut retrouver ce résultat en maximisant l'expression

$$\int_E dw q(w) \log \frac{f(w)}{q(w)} \quad \text{sous la contrainte d'égalité} \quad \int_E dw q(w) = 1 ,$$

par rapport à la fonction positive $q(w)$.

SOLUTION

D'après la réponse à la question (i)

$$p_Y(y) = \int_{\mathbb{R}^m} \int_{\mathbb{R}^s} dx da p_{X,Y|A=a}(x, y) p_A(a) = \int_{\mathbb{R}^m} \int_{\mathbb{R}^s} dx da q(x, a) \frac{p_{X,Y|A=a}(x, y) p_A(a)}{q(x, a)} ,$$

en multipliant et en divisant par une densité de probabilité $q(x, a)$ arbitraire strictement positive (ou ne s'annulant qu'aux points (x, a) où $p_{X,A,Y}(x, a, y) = p_{X,Y|A=a}(x, y) p_A(a)$ s'annule aussi). En utilisant l'inégalité de Jensen, il vient

$$\begin{aligned} \log p_Y(y) &= \log \int_{\mathbb{R}^m} \int_{\mathbb{R}^s} dx da q(x, a) \frac{p_{X,Y|A=a}(x, y) p_A(a)}{q(x, a)} \\ &\geq \int_{\mathbb{R}^m} \int_{\mathbb{R}^s} dx da q(x, a) \log \frac{p_{X,Y|A=a}(x, y) p_A(a)}{q(x, a)} . \end{aligned}$$

□

(iii) **Montrer que le maximum de la borne inférieure**

$$\int_{\mathbb{R}^m} \int_{\mathbb{R}^s} dx da q(x, a) \log \frac{p_{X,Y|A=a}(x, y) p_A(a)}{q(x, a)} ,$$

obtenue à la question (ii), par rapport à la densité de probabilité $q(x, a)$, est atteint précisément pour $q(x, a) = p_{X,A|Y=y}(x, a)$.

Le maximum de l'expression

$$\int_{\mathbb{R}^m} \int_{\mathbb{R}^s} dx da q(x, a) \log \frac{p_{X,Y|A=a}(x, y) p_A(a)}{q(x, a)},$$

par rapport à la densité de probabilité $q(x, a)$ est obtenu pour

$$q(x, a) = c p_{X,Y|A=a}(x, y) p_A(a) = c p_{X,A,Y}(x, a, y) = c p_Y(y) p_{X,A|Y=y}(x, a),$$

où la constante de normalisation c ne dépend pas des variables x et a , de sorte que

$$c p_Y(y) = 1 \quad \text{et} \quad q(x, a) = p_{X,A|Y=y}(x, a).$$

□

A partir de maintenant, l'objectif se résume à trouver un algorithme permettant de trouver le maximum de la borne inférieure par rapport à la densité de probabilité $q(x, a)$. L'idée de l'*estimation bayésienne variationnelle* est de rechercher $q(x, a)$ sous la forme factorisée $q(x, a) = q_X(x) q_A(a)$ et de maximiser itérativement par rapport à $q_X(x)$ puis par rapport à $q_A(a)$, et ainsi de suite. En d'autres termes, les solutions $q_X^{(p)}(x)$ et $q_A^{(p)}(a)$ à l'itération courante p , sont définies à l'aide des formules de mise-à-jour suivantes

$$q_X^{(p)}(x) = \operatorname{argmax}_{q_X(\cdot)} \int_{\mathbb{R}^m} \int_{\mathbb{R}^s} dx da q_X(x) q_A^{(p-1)}(a) \log \frac{p_{X,Y|A=a}(x, y) p_A(a)}{q_X(x) q_A^{(p-1)}(a)},$$

et

$$q_A^{(p)}(a) = \operatorname{argmax}_{q_A(\cdot)} \int_{\mathbb{R}^m} \int_{\mathbb{R}^s} dx da q_X^{(p)}(x) q_A(a) \log \frac{p_{X,Y|A=a}(x, y) p_A(a)}{q_X^{(p)}(x) q_A(a)},$$

à partir des solutions à l'itération précédente ($p - 1$). On espère ainsi que la densité de probabilité $q_A^{(p)}(a)$ converge, quand le nombre p d'itérations tend vers l'infini, vers la densité de probabilité *a posteriori* du paramètre, c'est-à-dire vers la densité de probabilité $p_{A|Y=y}(a)$ du vecteur aléatoire A sachant l'observation Y .

(iv) **Montrer que les deux étapes définies ci-dessus admettent les solutions explicites suivantes**

$$q_X^{(p)}(x) = c_X \exp \left\{ \int_{\mathbb{R}^s} da q_A^{(p-1)}(a) \log p_{X,Y|A=a}(x, y) \right\},$$

et

$$q_A^{(p)}(a) = c_A p_A(a) \exp \left\{ \int_{\mathbb{R}^m} dx q_X^{(p)}(x) \log p_{X,Y|A=a}(x, y) \right\},$$

où les constantes c_X et c_A désignent des constantes de normalisation.

On remarque que

$$\begin{aligned}
& \int_{\mathbb{R}^m} \int_{\mathbb{R}^s} dx da q_X(x) q_A^{(p-1)}(a) \log \frac{p_{X,Y|A=a}(x,y) p_A(a)}{q_X(x) q_A^{(p-1)}(a)} \\
&= \int_{\mathbb{R}^m} dx q_X(x) \int_{\mathbb{R}^s} da q_A^{(p-1)}(a) \log \frac{p_{X,Y|A=a}(x,y) p_A(a)}{q_X(x) q_A^{(p-1)}(a)} \\
&= \int_{\mathbb{R}^m} dx q_X(x) \log \frac{\exp \left\{ \int_{\mathbb{R}^s} da q_A^{(p-1)}(a) \log \frac{p_{X,Y|A=a}(x,y) p_A(a)}{q_A^{(p-1)}(a)} \right\}}{q_X(x)},
\end{aligned}$$

et d'après la remarque préliminaire, le maximum par rapport à la densité de probabilité $q_X(x)$ est obtenu pour

$$\begin{aligned}
q_X^{(p)}(x) &= c'_X \exp \left\{ \int_{\mathbb{R}^s} da q_A^{(p-1)}(a) \log \frac{p_{X,Y|A=a}(x,y) p_A(a)}{q_A^{(p-1)}(a)} \right\} \\
&= c'_X \exp \left\{ \int_{\mathbb{R}^s} da q_A^{(p-1)}(a) \log \frac{p_A(a)}{q_A^{(p-1)}(a)} \right\} \\
&\quad \exp \left\{ \int_{\mathbb{R}^s} da q_A^{(p-1)}(a) \log p_{X,Y|A=a}(x,y) \right\} \\
&= c_X \exp \left\{ \int_{\mathbb{R}^s} da q_A^{(p-1)}(a) \log p_{X,Y|A=a}(x,y) \right\},
\end{aligned}$$

où les constantes de normalisation c'_X et c_X ne dépendent pas de la variable x .

De la même manière, on remarque que

$$\begin{aligned}
& \int_{\mathbb{R}^m} \int_{\mathbb{R}^s} dx da q_X^{(p)}(x) q_A(a) \log \frac{p_{X,Y|A=a}(x,y) p_A(a)}{q_X^{(p)}(x) q_A(a)} \\
&= \int_{\mathbb{R}^s} da q_A(a) \int_{\mathbb{R}^m} dx q_X^{(p)}(x) \log \frac{p_{X,Y|A=a}(x,y) p_A(a)}{q_X^{(p)}(x) q_A(a)} \\
&= \int_{\mathbb{R}^s} da q_A(a) \log \frac{p_A(a) \exp \left\{ \int_{\mathbb{R}^m} dx q_X^{(p)}(x) \log \frac{p_{X,Y|A=a}(x,y)}{q_X^{(p)}(x)} \right\}}{q_A(a)},
\end{aligned}$$

et d'après la remarque préliminaire, le maximum par rapport à la densité de probabilité

$q_A(a)$ est obtenu pour

$$\begin{aligned}
 q_A^{(p)}(a) &= c'_A p_A(a) \exp \left\{ \int_{\mathbb{R}^m} dx q_X^{(p)}(x) \log \frac{p_{X,Y|A=a}(x,y)}{q_X^{(p)}(x)} \right\} \\
 &= c'_A \exp \left\{ - \int_{\mathbb{R}^m} dx q_X^{(p)}(x) \log q_X^{(p)}(x) \right\} \\
 &\quad p_A(a) \exp \left\{ \int_{\mathbb{R}^m} dx q_X^{(p)}(x) \log p_{X,Y|A=a}(x,y) \right\} \\
 &= c_A p_A(a) \exp \left\{ \int_{\mathbb{R}^m} dx q_X^{(p)}(x) \log p_{X,Y|A=a}(x,y) \right\} ,
 \end{aligned}$$

où les constantes de normalisation c'_A et c_A ne dépendent pas de la variable a .

□

A titre d'exemple, on considère le cas particulier suivant

$$\begin{cases} X = M + W , \\ Y = H X + V , \end{cases}$$

où le paramètre inconnu $A = (M, H)$ est supposé aléatoire. On fait les hypothèses suivantes

- le vecteur aléatoire W est gaussien centré, de matrice de covariance identité,
- le vecteur aléatoire V est gaussien centré, de matrice de covariance identité,
- la densité de probabilité *a priori* $p_A(m, h)$ du vecteur aléatoire $A = (M, H)$ est gaussienne, de moyenne (\bar{M}, \bar{H}) et de matrice de covariance identité,
- les vecteurs aléatoires W , V et A sont mutuellement indépendants.

(v) **Expliquer pourquoi le problème de l'estimation du vecteur aléatoire (X, A) sachant Y ne rentre pas dans le cadre de l'estimation MMSE pour les vecteurs aléatoires gaussiens.**

SOLUTION

D'après les hypothèses, le vecteur aléatoire (W, V, A) est gaussien, mais le vecteur aléatoire (X, Y, A) est le résultat d'une transformation *non-linéaire* du vecteur aléatoire (W, V, A) . On ne peut donc pas en déduire que le vecteur aléatoire (X, Y, A) est gaussien, et il n'est pas possible d'utiliser le cadre de l'estimation MMSE pour les vecteurs aléatoires gaussiens.

□

- (vi) **Monter par récurrence sur l'indice p que les solutions successives $q_X^{(p)}(x)$ et $q_A^{(p)}(a)$ sont des densités de probabilité gaussiennes, dont on caractérisera la moyenne et la matrice de covariance.**

SOLUTION

Il suffit de remarquer que conditionnellement à (X, A) le vecteur aléatoire Y est gaussien, de moyenne $H X$ et de matrice de covariance identité, et que conditionnellement à A le vecteur aléatoire X est gaussien, de moyenne M et de matrice de covariance identité. Il en résulte que pour tout $a = (m, h)$ fixé

$$\begin{aligned} p_{X,Y|A=a}(x, y) &= p_{Y|X=x,A=a}(y) p_{X|A=a}(x) \\ &= c \exp\left\{-\frac{1}{2} |y - h x|^2\right\} \exp\left\{-\frac{1}{2} |x - m|^2\right\}, \end{aligned}$$

de sorte que la log-densité

$$x \longmapsto \log p_{X,Y|A=a}(x, y) = -\frac{1}{2} |y - h x|^2 - \frac{1}{2} |x - m|^2 + \log c,$$

est une forme quadratique définie négative de la variable x , dont les coefficients dépendent de $a = (m, h)$: en effet

$$\log p_{X,Y|A=a}(x, y) = -\frac{1}{2} x^* (I + h^* h) x + x^* (h^* y + m) - \frac{1}{2} |y|^2 - \frac{1}{2} |m|^2 + \log c.$$

□

En revenant au cas général, on peut poser alternativement

$$q_X^{(p)}(x) = r_X^{(p)}(x) p_{X|Y=y,A=a_0}(x) = r_X^{(p)}(x) \frac{p_{X,Y|A=a_0}(x, y)}{p_{Y|A=a_0}(y)},$$

où a_0 est une valeur fixe du paramètre, et où l'inconnue est maintenant $r_X^{(p)}(x)$.

- (vii) **Montrer que les solutions données à la question (iv) peuvent se ré-écrire**

$$r_X^{(p)}(x) = c_X \exp \left\{ \int_{\mathbb{R}^s} da q_A^{(p-1)}(a) \log \frac{p_{X,Y|A=a}(x, y)}{p_{X,Y|A=a_0}(x, y)} \right\},$$

et

$$\begin{aligned} q_A^{(p)}(a) &= c_A p_A(a) \exp \left\{ \int_{\mathbb{R}^m} dx r_X^{(p)}(x) p_{X|Y=y,A=a_0}(x) \log \frac{p_{X,Y|A=a}(x, y)}{p_{X,Y|A=a_0}(x, y)} \right\} \\ &= c_A p_A(a) \exp \left\{ \mathbb{E} \left[r_X^{(p)}(X) \log \frac{p_{X,Y|A=a}(X, Y)}{p_{X,Y|A=a_0}(X, Y)} \mid Y = y, A = a_0 \right] \right\}, \end{aligned}$$

où les constantes c_X et c_A désignent d'autres constantes de normalisation.

Par définition

$$\begin{aligned}
r_X^{(p)}(x) &= q_X^{(p)}(x) \frac{p_{Y|A=a_0}(y)}{p_{X,Y|A=a_0}(x,y)} \\
&= c'_X \exp \left\{ \int_{\mathbb{R}^s} da q_A^{(p-1)}(a) \log p_{X,Y|A=a}(x,y) \right\} \frac{p_{Y|A=a_0}(y)}{p_{X,Y|A=a_0}(x,y)} \\
&= c'_X p_{Y|A=a_0}(y) \exp \left\{ \int_{\mathbb{R}^s} da q_A^{(p-1)}(a) \log \frac{p_{X,Y|A=a}(x,y)}{p_{X,Y|A=a_0}(x,y)} \right\} \\
&= c_X \exp \left\{ \int_{\mathbb{R}^s} da q_A^{(p-1)}(a) \log \frac{p_{X,Y|A=a}(x,y)}{p_{X,Y|A=a_0}(x,y)} \right\} ,
\end{aligned}$$

où les constantes de normalisation c'_X et c_X ne dépendent pas de la variable x .

De la même manière

$$\begin{aligned}
q_A^{(p)}(a) &= c'_A p_A(a) \exp \left\{ \int_{\mathbb{R}^m} dx q_X^{(p)}(x) \log p_{X,Y|A=a}(x,y) \right\} \\
&= c'_A p_A(a) \exp \left\{ \int_{\mathbb{R}^m} dx q_X^{(p)}(x) \log \frac{p_{X,Y|A=a}(x,y)}{p_{X,Y|A=a_0}(x,y)} \right\} \\
&\quad \exp \left\{ \int_{\mathbb{R}^m} dx q_X^{(p)}(x) \log p_{X,Y|A=a_0}(x,y) \right\} \\
&= c_A p_A(a) \exp \left\{ \int_{\mathbb{R}^m} dx q_X^{(p)}(x) \log \frac{p_{X,Y|A=a}(x,y)}{p_{X,Y|A=a_0}(x,y)} \right\} \\
&= c_A p_A(a) \exp \left\{ \int_{\mathbb{R}^m} dx p_{X|Y=y,A=a_0}(x) r_X^{(p)}(x) \log \frac{p_{X,Y|A=a}(x,y)}{p_{X,Y|A=a_0}(x,y)} \right\} ,
\end{aligned}$$

où les constantes de normalisation c'_A et c_A ne dépendent pas de la variable a , et on remarque finalement que

$$\begin{aligned}
&\int_{\mathbb{R}^m} dx p_{X|Y=y,A=a_0}(x) r_X^{(p)}(x) \log \frac{p_{X,Y|A=a}(x,y)}{p_{X,Y|A=a_0}(x,y)} \\
&= \mathbb{E}[r_X^{(p)}(X) \log \frac{p_{X,Y|A=a}(X,Y)}{p_{X,Y|A=a_0}(X,Y)} \mid Y = y, A = a_0] .
\end{aligned}$$

□

On considère finalement le cas d'un système linéaire gaussien

$$\begin{cases} X_k = F X_{k-1} + W_k , \\ Y_k = H X_k + V_k , \end{cases}$$

où le paramètre inconnu $A = (F, H)$ est supposé aléatoire. On fait les hypothèses suivantes :

- le vecteur aléatoire X_0 est gaussien, de moyenne \bar{X}_0 et de matrice de covariance Q_0^X ,
- la suite aléatoire $\{W_k\}$ est un bruit blanc gaussien centré de matrice de covariance identité,
- la suite aléatoire $\{V_k\}$ est un bruit blanc gaussien centré de matrice de covariance identité,
- la densité de probabilité *a priori* $p_A(f, h)$ du vecteur aléatoire $A = (F, H)$ est gaussienne, de moyenne (\bar{F}, \bar{H}) et de matrice de covariance identité,
- les vecteurs / suites aléatoires X_0 , $A = (F, H)$, $\{W_k\}$ et $\{V_k\}$ sont mutuellement indépendants.

(viii) **En utilisant les expressions obtenues à la question (vii), montrer que la mise en œuvre de l'algorithme précédent pour l'estimation du paramètre inconnu $A = (F, H)$ à partir des observations $Y_{0:n}$ se ramène à chaque itération au calcul de l'espérance conditionnelle d'une certaine fonction des états cachés $X_{0:n}$ sachant les observations $Y_{0:n}$ et pour une valeur particulière $A_0 = (F_0, H_0)$ du paramètre.**