

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

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**

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

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 $z \mapsto \log z$).

(iii) **Montrer 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 $q(x, a) = p_{X,A|Y=y}(x, a)$.

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 p , sont définies à partir des solutions $q_X^{(p-1)}(x)$ et $q_A^{(p-1)}(a)$ à l'itération $(p-1)$, 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

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

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.

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.**
- (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.**

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.

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.**