

École Nationale Supérieure de Techniques Avancées
module : Commande des Systèmes

examen du cours B7–1

“Filtrage bayésien et approximation particulière”

mercredi 15 octobre 2014, 8:30 à 10:00

PROBLÈME

L’objectif de ce problème est d’étudier l’approximation par échantillonnage pondéré d’une distribution de Gibbs–Boltzman associée à une fonction positive et à une distribution de probabilité particulière, décrite par un mélange fini de distributions de probabilité.

On considère donc une distribution de probabilité

$$m(dx) = \sum_{j=1}^M w_j m_j(dx) \quad \text{avec} \quad \sum_{j=1}^M w_j = 1 ,$$

sous la forme d’un mélange fini de M distributions de probabilités (m_1, \dots, m_M) affectées des poids positifs normalisés (w_1, \dots, w_M) , et on considère la distribution de Gibbs–Boltzman associée

$$\mu = g \cdot m = \frac{g m}{\langle m, g \rangle} \quad \text{c’est-à-dire que} \quad \mu(dx) = \frac{\sum_{j=1}^M w_j g(x) m_j(dx)}{\sum_{j=1}^M w_j \langle m_j, g \rangle} ,$$

où g est une fonction positive. On définit aussi la distribution non-normalisée

$$\gamma = g m \quad \text{c’est-à-dire que} \quad \gamma(dx) = \sum_{j=1}^M w_j g(x) m_j(dx) .$$

Au lieu de l’hypothèse faite en cours qu’il est facile de *simuler* une variable aléatoire selon chacune des composantes du mélange, on suppose ici que chacune des composantes

du mélange possède une densité par rapport à une mesure positive de référence λ , et que l'expression de cette densité est connue explicitement. En d'autres termes

$$m(dx) = \sum_{j=1}^M w_j m_j(x) \lambda(dx) \quad \text{avec} \quad \sum_{j=1}^M w_j = 1 ,$$

et

$$\gamma(dx) = \sum_{j=1}^M w_j g(x) m_j(x) \lambda(dx) ,$$

et on suppose qu'il est facile, pour tout $j = 1, \dots, M$

- d'évaluer le produit $g(x) m_j(x)$ pour tout $x \in E$.

L'approximation proposée repose sur la factorisation suivante, valide pour chacune des composantes du mélange : pour tout $j = 1, \dots, M$

$$w_j g(x) m_j(x) = r_j(x) \theta_j \pi_j(x) \quad \text{avec} \quad r_j(x) = \frac{w_j g(x) m_j(x)}{\theta_j \pi_j(x)} ,$$

pour tout $x \in E$, où

- la densité de probabilité π_j ne s'annule qu'aux points $x \in E$ où le produit $g(x) m_j(x)$ est déjà nul,
- le poids positif θ_j n'est nul que si le poids w_j est déjà nul,

et on adoptera la convention $0/0 = 0$. En d'autres termes, cette factorisation permet de ré-écrire la distribution non-normalisée sous la forme équivalente

$$\gamma(dx) = \sum_{j=1}^M r_j(x) \theta_j \pi_j(x) \lambda(dx) \quad \text{avec} \quad \sum_{j=1}^M \theta_j = 1 ,$$

et on suppose qu'il est facile, pour tout $j = 1, \dots, M$

- de *simuler* une variable aléatoire de densité π_j ,
- et d'évaluer la fonction $\pi_j(x)$ pour tout $x \in E$.

Intuitivement, l'approximation proposée consiste à échantillonner selon les densités (π_1, \dots, π_M) et selon les poids $(\theta_1, \dots, \theta_M)$ et à pondérer judicieusement les échantillons obtenus. Pour rendre rigoureuse cette approche jusqu'ici intuitive, l'idée consiste à interpréter la distribution non-normalisée γ comme la distribution marginale (définie sur E) d'une distribution non-normalisée définie sur l'ensemble produit $E' = \{1, \dots, M\} \times E$.

Soit (I, X) la variable aléatoire à valeurs dans l'ensemble produit $E' = \{1, \dots, M\} \times E$ et de distribution de probabilité jointe η' , vue comme une famille $\eta' = (\eta_1, \dots, \eta_M)$ de M distributions de probabilité sur l'ensemble E , définie par

$$\mathbb{P}[I = j, X \in dx] = \eta_j(dx) = \theta_j \pi_j(x) \lambda(dx) ,$$

pour tout $j = 1, \dots, M$.

- (i) **Décrire la distribution de probabilité marginale de la variable aléatoire I seulement, et la distribution de probabilité conditionnelle de la variable aléatoire X sachant $I = j$. En déduire un moyen pratique de simuler la variable aléatoire (I, X) .**

Sur l'ensemble produit $E' = \{1, \dots, M\} \times E$, on introduit la distribution non-normalisée γ' , vue comme une famille $\gamma' = (\gamma_1, \dots, \gamma_M)$ de M distributions non-normalisées sur l'ensemble E , définie par

$$\gamma_j(dx) = r_j(x) \theta_j \pi_j(x) \lambda(dx) ,$$

pour tout $j = 1, \dots, M$.

- (ii) **Montrer que la distribution non-normalisée γ peut s'interpréter comme la distribution marginale (définie sur l'ensemble E) de la distribution non-normalisée $\gamma' = (\gamma_1, \dots, \gamma_M)$ (définie sur l'ensemble produit $E' = \{1, \dots, M\} \times E$).**
- (iii) **Montrer que la distribution non-normalisée γ' définie sur l'ensemble produit $E' = \{1, \dots, M\} \times E$ peut s'interpréter comme le produit**
- **d'une distribution de probabilité jointe définie sur l'ensemble produit E' , vue comme une famille de M distributions de probabilités définies sur l'ensemble E ,**
 - **et d'une fonction positive définie sur l'ensemble produit E' , vue comme une famille de M fonctions positives définies sur l'ensemble E ,**
- dont on donnera les expressions.**
- (iv) **En utilisant cette factorisation, proposer une approximation par échantillonnage pondéré de la distribution non-normalisée $\gamma' = (\gamma_1, \dots, \gamma_M)$ définie sur l'ensemble produit $E' = \{1, \dots, M\} \times E$.**
- (v) **En utilisant le résultat énoncé à la question (ii), en déduire une approximation par échantillonnage pondéré de la distribution non-normalisée γ définie sur l'ensemble E .**

(vi) **En déduire une approximation par échantillonnage pondéré de la distribution de Gibbs–Boltzmann μ définie sur l'ensemble E .**

On considère l'approximation

$$\gamma \approx \widehat{\gamma}_N = \frac{1}{N} \sum_{i=1}^N r_{I_i}(\xi_i) \delta_{\xi_i} ,$$

obtenue en réponse à la question (v), où indépendamment pour tout $i = 1, \dots, N$ la variable aléatoire (I_i, ξ_i) a pour distribution de probabilité jointe $\eta' = (\eta_1, \dots, \eta_M)$ définie sur l'ensemble produit $E' = \{1, \dots, M\} \times E$. Concrètement

$$\langle \gamma, \phi \rangle \approx \langle \widehat{\gamma}_N, \phi \rangle = \frac{1}{N} \sum_{i=1}^N r_{I_i}(\xi_i) \phi(\xi_i) ,$$

pour toute fonction mesurable bornée ϕ définie sur l'ensemble E .

(vii) **Montrer que $\langle \widehat{\gamma}_N, \phi \rangle$ est un estimateur non-biaisé de $\langle \gamma, \phi \rangle$.**

(viii) **Calculer la variance $\mathbb{E} | \langle \widehat{\gamma}_N, \phi \rangle - \langle \gamma, \phi \rangle |^2$ de l'erreur d'approximation.**

COMMENTAIRE

Cette stratégie s'applique notamment dans le cadre du filtrage bayésien, et produit une classe d'approximations particulières connues sous le sigle APF, pour *auxiliary particle filter*. Concrètement, si on dispose d'une approximation particulière du filtre bayésien sous la forme

$$\mu_{k-1}^N = \sum_{i=1}^N w_{k-1}^i \delta_{\xi_{k-1}^i} \quad \text{avec} \quad \sum_{i=1}^N w_{k-1}^j = 1 ,$$

alors on obtient à l'instant suivant une approximation particulière du filtre bayésien sous la forme

$$g_k(x') (\mu_{k-1}^N Q_k)(dx') = \sum_{i=1}^N w_{k-1}^i g_k(x') Q_k(\xi_{k-1}^i, dx') \quad \text{avec} \quad \sum_{i=1}^N w_{k-1}^j = 1 ,$$

à une constante multiplicative près. On remarque que cette distribution non-normalisée est bien de la forme étudiée ici, c'est-à-dire

$$\gamma(dx') = \sum_{i=1}^N w_i g(x') m_i(dx') .$$

avec les identifications

- $g(x') = g_k(x')$ pour tout $x' \in E$,
- $w_i = w_{k-1}^i$ et $m_i(dx') = Q_k(\xi_{k-1}^i, dx')$ pour tout $i = 1, \dots, N$.

L'approximation particulière proposée par le filtre APF repose sur la factorisation suivante : pour tout $i = 1, \dots, N$

$$w_{k-1}^i g_k(x') m_k^i(x') = r_k^i(x') \theta_k^i \pi_k^i(x') \quad \text{avec} \quad r_k^i(x') = \frac{w_{k-1}^i g_k(x') m_k^i(x')}{\theta_k^i \pi_k^i(x')},$$

pour tout $x' \in E$, où on s'autorise à définir le nouveau poids $\theta_k^i = \theta(\xi_{k-1}^i)$ comme fonction de la position ξ_{k-1}^i de la particule à l'instant précédent. Cette flexibilité offerte permet par exemple de définir

$$\theta_k^i = \int_E g_k(x') m_k^i(dx'),$$

si cette expression est disponible explicitement, ou sinon

$$\theta_k^i = g_k\left(\int_E x' m_k^i(dx')\right),$$

qui est plus souvent disponible, ce qui permet de sélectionner les particules dans la population courante dont on sait prédire que les descendants seront consistants avec l'observation recueillie à l'instant suivant.