

**École Nationale Supérieure de Techniques Avancées**  
**examen du cours SOD333**  
**“Filtrage bayésien et approximation particulière”**

**vendredi 23 octobre 2020, 13:30 à 16:00**

L’objectif de ce problème est d’étudier le *lisseur* bayésien dans le cas simple d’un modèle de Markov caché, et d’établir plusieurs formes d’équations récurrentes décrivant son évolution. Ici, l’horizon temporel est fixé, c’est-à-dire que toutes les observations recueillies entre l’instant initial 0 et l’instant final  $n$  sont disponibles et peuvent être utilisées pour estimer l’état caché à un instant  $k$  intermédiaire entre 0 et  $n$  (le cas où  $k = n$  correspond bien sûr au cas du *filtre* bayésien vu en cours).

Pour fixer les idées, on considère un modèle de Markov caché, où les états cachés  $\{X_k\}$  forment une chaîne de Markov à valeurs dans  $E$ , et où *conditionnellement aux états cachés* les observations  $\{Y_k\}$  forment une suite de variables aléatoires indépendantes (hypothèse de canal sans mémoire). Ce modèle est caractérisé par

- la distribution de probabilité initiale  $\eta_0(dx)$  à l’instant 0,
- le noyau de probabilités de transition  $Q_k(x, dx')$ , c’est-à-dire que

$$Q_k(x, dx') = \mathbb{P}[X_k \in dx' \mid X_{k-1} = x] ,$$

pour tout  $k = 1, \dots, n$ ,

- la fonction de vraisemblance  $g_k(x')$  pour tout  $k = 0, 1, \dots, n$ .

Ici l’instant final  $n$  est fixé, et on cherche à estimer l’état caché à un instant  $k$  intermédiaire entre l’instant initial 0 et l’instant final  $n$ . Il s’agit donc de calculer la distribution de probabilité conditionnelle de l’état caché  $X_k$  sachant toutes les observations  $Y_{0:n} = (Y_0, Y_1, \dots, Y_n)$ , définie par

$$\mu_{k|n}(dx) = \mathbb{P}[X_k \in dx \mid Y_{0:n}] .$$

On rappelle que le filtre bayésien  $\mu_k$  peut s’exprimer comme

$$\langle \mu_k, \phi \rangle = \frac{\langle \gamma_k, \phi \rangle}{\langle \gamma_k, 1 \rangle} ,$$

où la distribution non-normalisée  $\gamma_k$  est définie par

$$\langle \gamma_k, \phi \rangle = \mathbb{E} \left[ \phi(X_k) \prod_{p=0}^k g_p(X_p) \right] ,$$

pour toute fonction mesurable bornée  $\phi$ .

- (i) En s'inspirant de la preuve vue en cours pour le filtre bayésien, montrer que le lisseur bayésien  $\mu_{k|n}$  peut s'exprimer comme

$$\langle \mu_{k|n}, \phi \rangle = \frac{\langle \gamma_{k|n}, \phi \rangle}{\langle \gamma_{k|n}, 1 \rangle},$$

où la distribution non-normalisée  $\gamma_{k|n}$  est définie par

$$\langle \gamma_{k|n}, \phi \rangle = \mathbb{E}[\phi(X_k) \prod_{p=0}^n g_p(X_p)],$$

pour toute fonction mesurable bornée  $\phi$ .

### ÉQUATIONS FORWARD-BACKWARD

On introduit la fonction

$$v_k(x) = \mathbb{E}[\prod_{q=k+1}^n g_q(X_q) \mid X_k = x], \quad (1)$$

pour tout  $k = 0, 1, \dots, n-1$ , avec la convention  $v_n \equiv 1$  pour  $k = n$ .

- (ii) En séparant explicitement les termes qui dépendent des états passés  $X_{0:k}$  et les termes qui dépendent des états futurs  $X_{k+1:n}$ , montrer que

$$\langle \gamma_{k|n}, \phi \rangle = \langle \gamma_k, v_k \phi \rangle,$$

pour toute fonction mesurable bornée  $\phi$ , et en déduire que

$$\gamma_{k|n} = v_k \gamma_k \quad \text{et} \quad \mu_{k|n} = \frac{v_k \mu_k}{\langle \mu_k, v_k \rangle} = v_k \cdot \mu_k, \quad (2)$$

pour tout  $k = 0, 1, \dots, n$ .

Plus généralement, on introduit la fonction

$$f_k(x) = \mathbb{E}[\phi(X_n) \prod_{q=k+1}^n g_q(X_q) \mid X_k = x], \quad (3)$$

pour tout  $k = 0, 1, \dots, n-1$ , avec la convention  $f_n = \phi$  pour  $k = n$ . Pour  $x \in E$  fixé, cette expression peut s'interpréter comme une espérance pour le modèle de Markov caché caractérisé par

- la distribution de probabilité initiale  $\delta_x$  à l'instant  $k$ ,

- le noyau de probabilités de transition  $Q_p(x, dx')$ , pour tout  $p = k + 1, \dots, n$ ,
- la fonction de vraisemblance  $g_p(x')$  pour tout  $p = k + 1, \dots, n$ .

(iii) **Montrer que la suite de fonctions  $\{f_k\}$  définie en (3) vérifie l'équation récurrente dans le sens rétrograde**

$$f_{k-1} = Q_k(g_k f_k) , \quad (4)$$

pour tout  $k = n, n - 1, \dots, 1$ , avec la condition initiale  $f_n = \phi$  pour  $k = n$ .

**Dans le cas particulier  $\phi \equiv 1$ , en déduire que la suite de fonctions  $\{v_k\}$  définie en (1) vérifie l'équation récurrente dans le sens rétrograde**

$$v_{k-1} = Q_k(g_k v_k) , \quad (5)$$

pour tout  $k = n, n - 1, \dots, 1$ , avec la condition initiale  $v_n \equiv 1$  pour  $k = n$ .

On rappelle que la distribution de filtrage non-normalisée  $\gamma_k$  vérifie une équation récurrente dans le sens direct

$$\gamma_k = g_k (\gamma_{k-1} Q_k) , \quad (6)$$

pour tout  $k = 1, \dots, n$ , avec la condition initiale  $\gamma_0 = g_0 \eta_0$  pour  $k = 0$ .

(iv) **Montrer que les équations (6) et (4) sont des équations duales, dans le sens où l'expression  $\langle \gamma_k, f_k \rangle$ , et en particulier l'expression  $\langle \gamma_k, v_k \rangle$  obtenue pour  $\phi \equiv 1$ , ne dépend pas de  $k = 0, 1, \dots, n$ .**

**En déduire que la constante de normalisation  $\langle \gamma_{k|n}, 1 \rangle$  de la distribution non-normalisée  $\gamma_{k|n}$  ne dépend pas de  $k = 0, 1, \dots, n$ .**

Dans cette première approche, on résoud séparément

- une équation récurrente dans le sens direct pour le filtre bayésien  $\mu_k$ ,
- une équation récurrente dans le sens rétrograde pour la fonction  $v_k$ ,

et on obtient le lisseur bayésien  $\mu_{k|n}$  grace à la relation (2).

## ÉQUATION BACKWARD POUR LE LISSEUR BAYÉSIEN

L'objectif ici est de montrer qu'il est possible de combiner les équations (2) et (6) pour éliminer la fonction  $v_k$  et obtenir une équation récurrente dans le sens rétrograde pour le lisseur bayésien  $\mu_{k|n}$ .

Pour toute distribution de probabilité  $\mu$  définie sur  $E$ , on considère le noyau de probabilités de transition  $Q_k^B(\mu, x', dx)$  agissant dans le sens rétrograde, paramétré par la distribution  $\mu$ , et défini implicitement par

$$\mu(dx) Q_k(x, dx') = \mu Q_k(dx') Q_k^B(\mu, x', dx) ,$$

soit, en terme de densités de transition telles que  $Q_k(x, dx') = q_k(x' | x) dx'$  si celles-ci existent

$$\mu(dx) q_k(x' | x) = \left[ \int_E q_k(x' | x) \mu(dx) \right] Q_k^B(\mu, x', dx) ,$$

ce qui donne l'expression explicite

$$Q_k^B(\mu, x', dx) = \frac{q_k(x' | x) \mu(dx)}{\int_E q_k(x' | x) \mu(dx)} ,$$

pour tout  $k = 1, \dots, n$ . En particulier pour le filtre bayésien  $\mu_{k-1}$ , on a

$$\mu_{k-1}(dx) Q_k(x, dx') = \mu_{k-1} Q_k(dx') Q_k^B(\mu_{k-1}, x', dx) ,$$

et pour la distribution non-normalisée  $\gamma_{k-1}$

$$\gamma_{k-1}(dx) Q_k(x, dx') = \gamma_{k-1} Q_k(dx') Q_k^B(\mu_{k-1}, x', dx) ,$$

pour tout  $k = 1, \dots, n$ .

(v) **Montrer que**

$$\langle \gamma_{k-1|n}, \phi \rangle = \langle \gamma_{k|n}, Q_k^B(\mu_{k-1}) \phi \rangle ,$$

**pour toute fonction mesurable bornée  $\phi$ , de sorte que**

$$\gamma_{k-1|n} = \gamma_{k|n} Q_k^B(\mu_{k-1}) ,$$

**pour tout  $k = n, n-1, \dots, 1$ , avec la condition initiale  $\gamma_{n|n} = \gamma_n$  pour  $k = n$ .**

**En déduire que le lisseur bayésien vérifie l'équation de récurrence dans le sens rétrograde**

$$\mu_{k-1|n} = \mu_{k|n} Q_k^B(\mu_{k-1}) , \tag{7}$$

**pour tout  $k = n, n-1, \dots, 1$ , avec la condition initiale  $\mu_{n|n} = \mu_n$  pour  $k = n$ .**

- (vi) Au vu de l'équation (7), montrer que le lisseur bayésien  $\mu_{k|n}$  peut s'interpréter comme la distribution de probabilité inconditionnelle de l'état  $X_k^B$  d'une chaîne de Markov rétrograde  $\{X_k^B\}$ , c'est-à-dire que

$$\mu_{k|n}(dx) = \mathbb{P}[X_k^B \in dx] ,$$

pour tout  $k = n, n-1, \dots, 0$ .

Donner les caractéristiques de la chaîne de Markov  $\{X_k^B\}$ .

Dans cette deuxième approche, on résoud

- d'abord une équation récurrente dans le sens direct pour le filtre bayésien  $\mu_k$ ,
- puis une équation récurrente dans le sens rétrograde pour le lisseur bayésien  $\mu_{k|n}$ .

#### ÉQUATION FORWARD POUR LE LISSEUR BAYÉSIEN

L'objectif ici est de montrer qu'il est également possible de combiner les équations (2) et (5) pour éliminer la distribution de probabilité  $\mu_k$  et obtenir une équation récurrente dans le sens direct pour le lisseur bayésien  $\mu_{k|n}$ .

Pour toute fonction positive  $v$  définie sur  $E$ , on considère le noyau de probabilités de transition  $Q_k^F(v, x, dx')$  agissant dans le sens direct, paramétré par la fonction  $v$ , et défini explicitement par

$$Q_k^F(v, x, dx') = \frac{Q_k(x, dx') g_k(x') v(x')}{Q_k(g_k v)(x)} ,$$

pour tout  $k = 1, \dots, n$ .

- (vii) En particulier pour la fonction  $v_k$  définie en (2), montrer que

$$Q_k^F(v_k) \phi = \frac{Q_k(g_k v_k \phi)}{v_{k-1}} .$$

pour tout  $k = 1, \dots, n$  et pour toute fonction mesurable bornée  $\phi$ .

- (viii) Montrer que

$$\langle \mu_{k|n}, \phi \rangle = \langle \mu_{k-1|n}, Q_k^F(v_k) \phi \rangle ,$$

pour toute fonction mesurable bornée  $\phi$ , de sorte que

$$\mu_{k|n} = \mu_{k-1|n} Q_k^F(v_k) , \tag{8}$$

pour tout  $k = 1, \dots, n$ , avec la condition initiale  $\mu_{0|n} = (v_0 g_0) \cdot \eta_0$  pour  $k = 0$ .

- (ix) Au vu de l'équation (8), montrer que le lisseur bayésien  $\mu_{k|n}$  peut s'interpréter comme la distribution de probabilité inconditionnelle de l'état  $X_k^F$  d'une chaîne de Markov  $\{X_k^F\}$ , c'est-à-dire que

$$\mu_{k|n}(dx) = \mathbb{P}[X_k^F \in dx] ,$$

pour tout  $k = 0, 1, \dots, n$ .

Donner les caractéristiques de la chaîne de Markov  $\{X_k^F\}$ .

Dans cette troisième approche, on résoud

- d'abord une équation récurrente dans le sens rétrograde pour la fonction  $v_k$ ,
- puis une équation récurrente dans le sens direct pour le lisseur bayésien  $\mu_{k|n}$ .