

oooooooo

o  
oo  
oooooooo

o  
oooo  
oooooooooooooooooooo  
oooooooooooooooooooooooooooo

oooooooooooooooooooo ooooooooooooooooooooo

# Modèles de Markov Cachés

François Le Gland  
INRIA Rennes et IRMAR

<http://www.irisa.fr/aspi/legland/rennes-1/>

**classification bayésienne**  
●○○○○○○○○

modèles de Markov cachés  
○  
○○○  
○○○○○○○○○○

équations forward / backward de Baum  
○  
○○○○○  
○○○○○○○○○○○○○○○○  
○○○○○○○○○○○○○○○○○○○○○○○○

algorithme de Viterbi  
○○

re-estimation de Baum-Welch  
○○

**classification bayésienne**

modèles de Markov cachés

équations forward / backward de Baum

algorithme de Viterbi

re-estimation de Baum-Welch

détection de changement

















retour au cadre *dynamique* : on rappelle qu'il s'agit d'estimer l'hypothèse  $X_n$  (ou l'hypothèse  $X_k$  à un instant intermédiaire) au vu des observations  $(Y_0, \dots, Y_n)$

un des objectifs de ce cours est de fournir des algorithmes efficaces pour le calcul des probabilités conditionnelles

$$p_n^i = \mathbb{P}[X_n = i \mid Y_0, \dots, Y_n] \quad \text{ou} \quad q_k^i = \mathbb{P}[X_k = i \mid Y_0, \dots, Y_n]$$

dans le cas particulier où la suite des hypothèses et des observations forme un modèle de Markov caché

la première étape consiste à introduire et à étudier la notion de modèle de Markov caché



classification bayésienne

**modèles de Markov cachés**

chaînes de Markov à espace d'état fini

modèles de Markov cachés

équations forward / backward de Baum

algorithme de Viterbi

re-estimation de Baum–Welch

détection de changement



une chaîne de Markov  $\{X_k\}$  est entièrement caractérisée par la donnée

- ▶ de la *loi initiale*  $\nu = (\nu_i)$

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

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

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

qu'on suppose indépendante de l'instant  $k$  (chaîne de Markov *homogène*)

il suffit donc d'une donnée locale (les probabilités de transition entre deux instants successifs) pour caractériser de façon globale une chaîne de Markov











oooooooo

 o  
 oo  
 oo●oooo

 o  
 oooo  
 oooooooooooooooooo  
 oooooooooooooooooo

oooooooooooooooooooo ooooooooooooooooooooo

**Proposition** dans le cas *symbolique*, la *distribution de probabilité* du modèle de Markov caché  $\{(X_k, Y_k)\}$ , de loi initiale  $\nu$ , de matrice de transition  $\pi$ , et de probabilités d'émission  $b$ , est donnée par

$$\begin{aligned} \mathbb{P}[X_0 = i_0, \dots, X_k = i_k, Y_0 = \ell_0, \dots, Y_k = \ell_k] = \\ = \nu_{i_0} \pi_{i_0, i_1} \cdots \pi_{i_{k-1}, i_k} b_{i_0}^{\ell_0} \cdots b_{i_k}^{\ell_k} \end{aligned}$$

pour tout instant  $k$ , toute suite  $i_0, \dots, i_k \in E$ , et toute suite  $\ell_0, \dots, \ell_k \in O$

dans le cas *numérique*, la *distribution de probabilité* du modèle de Markov caché  $\{(X_k, Y_k)\}$ , de loi initiale  $\nu$ , de matrice de transition  $\pi$ , et de densités d'émission  $g$ , est donnée par

$$\begin{aligned} \mathbb{P}[X_0 = i_0, \dots, X_k = i_k, Y_0 \in dy_0, \dots, Y_k \in dy_k] = \\ = \nu_{i_0} \pi_{i_0, i_1} \cdots \pi_{i_{k-1}, i_k} g_{i_0}(y_0) \cdots g_{i_k}(y_k) dy_0 \cdots dy_k \end{aligned}$$

pour tout instant  $k$ , toute suite  $i_0, \dots, i_k \in E$ , et toute suite  $y_0, \dots, y_k \in \mathbb{R}^d$





○○○○○○○○○

○  
○○○  
○○○○○●○○○○  
○○○○○  
○○○○○○○○○○○○○○○  
○○○○○○○○○○○○○○○○○○○

○○○○○○○○○○○○○○○○○○○ ○○○○○○○○○○○○○○○○○○○○

- ▶ **Estimer** l'état de la chaîne : étant donnée une suite d'observations  $(Y_0, \dots, Y_n)$ , il s'agit d'estimer de façon réursive l'état présent  $X_n$  (problème de *filtrage*), ou bien d'estimer un état intermédiaire  $X_k$  pour  $k = 0 \dots n$  (problème de *lissage*), ou encore d'estimer globalement la suite d'états  $(X_0, \dots, X_n)$ , pour un modèle donné  $M$ 
  - la réponse aux deux premiers problèmes est fournie par les équations *forward* et *backward* de Baum, qui permettent de calculer la distribution de probabilité conditionnelle de l'état  $X_k$  sachant les observations  $(Y_0, \dots, Y_n)$
  - la réponse au dernier problème est fournie par un algorithme de *programmation dynamique*, l'algorithme de Viterbi, qui permet de maximiser la distribution de probabilité conditionnelle de la suite d'états  $(X_0, \dots, X_n)$  sachant les observations  $(Y_0, \dots, Y_n)$



classification bayésienne

modèles de Markov cachés

équations forward / backward de Baum

équation forward

équation forward

équation backward

algorithme de Viterbi

re-estimation de Baum-Welch

détection de changement









et pour la **vraisemblance** du modèle (obtenue en utilisant la suite des observations  $(Y_0, \dots, Y_n)$  à la place des variables muettes) :

- ▶ dans le cas **symbolique**

$$L_n = \sum_{i_0, \dots, i_n \in E} \nu_{i_0} \pi_{i_0, i_1} \cdots \pi_{i_{n-1}, i_n} b_{i_0}^{Y_0} \cdots b_{i_n}^{Y_n}$$

- ▶ et dans le cas **numérique**

$$L_n = \sum_{i_0, \dots, i_n \in E} \nu_{i_0} \pi_{i_0, i_1} \cdots \pi_{i_{n-1}, i_n} g_{i_0}(Y_0) \cdots g_{i_n}(Y_n)$$

on en déduit les identités suivantes : dans le cas **symbolique**

$$\mathbb{P}[X_0 = i_0, \dots, X_n = i_n \mid Y_0, \dots, Y_n] L_n = \nu_{i_0} \pi_{i_0, i_1} \cdots \pi_{i_{n-1}, i_n} b_{i_0}^{Y_0} \cdots b_{i_n}^{Y_n}$$

et dans le cas **numérique**

$$\mathbb{P}[X_0 = i_0, \dots, X_n = i_n \mid Y_0, \dots, Y_n] L_n = \nu_{i_0} \pi_{i_0, i_1} \cdots \pi_{i_{n-1}, i_n} g_{i_0}(Y_0) \cdots g_{i_n}(Y_n)$$

**Remarque** le nombre d'opérations nécessaires pour calculer la distribution de probabilité des observations  $(Y_0, \dots, Y_n)$  à partir de cette méthode élémentaire est considérable

pour chaque trajectoire possible  $(i_0, \dots, i_n)$  de la chaîne de Markov, il faut effectuer le produit de  $2(n + 1)$  termes, et il y a  $|E|^{n+1}$  trajectoires possibles différentes

le nombre total d'opérations élémentaires (additions et multiplications) à effectuer est donc de l'ordre de :  $2(n + 1) |E|^{n+1}$

ce nombre croît *exponentiellement* avec le nombre  $n$  d'observations



## équation forward

on définit la variable *forward*  $p_k = (p_k^i)$  — vue comme un *vecteur-ligne* — par

$$p_k^i = \mathbb{P}[X_k = i \mid Y_0, \dots, Y_k] L_k \quad \text{pour tout } i \in E$$

**Remarque** la variable forward permet de calculer la distribution de probabilité conditionnelle de l'état présent  $X_k$  sachant les observations  $(Y_0, \dots, Y_k)$  :

$$\mathbb{P}[X_k = i \mid Y_0, \dots, Y_k] = \frac{1}{L_k} p_k^i \quad \text{pour tout } i \in E$$

(en ce sens,  $p_k$  est une distribution de probabilité non-normalisée), et la constante de normalisation

$$L_k = \sum_{i \in E} p_k^i$$

s'interprète comme la vraisemblance du modèle sachant les observations  $(Y_0, \dots, Y_k)$



○○○○○○○○○○

○

○○○

○○○○○○○○○○

○

○○○○○

○○●○○○○○○○○○○○○○○○

○○○○○○○○○○○○○○○○○○○○○○○

○○○

**Remarque** ce résultat énoncé composante–par–composante peut être aussi formulé pour la variable forward vue comme un *vecteur–ligne*

► dans le cas *symbolique*

$$p_k = p_{k-1} \pi B^{Y_k} \quad \text{et} \quad p_0 = \nu B^{Y_0}$$

► et dans le cas *numérique*

$$p_k = p_{k-1} \pi G(Y_k) \quad \text{et} \quad p_0 = \nu G(Y_0)$$

avec les matrices *diagonales* définies par

$$B^\ell = \text{diag}(b_j^\ell) \quad \text{pour tout } \ell \in O$$

et

$$G(y) = \text{diag}(g_i(y)) \quad \text{pour tout } y \in \mathbb{R}^d$$

respectivement

**Preuve** on considère uniquement le cas *symbolique* : on rappelle l'identité suivante, obtenue avec la méthode élémentaire

$$\begin{aligned} &\mathbb{P}[X_0 = i_0, \dots, X_{k-2} = i_{k-2}, X_{k-1} = i, X_k = j \mid Y_0, \dots, Y_k] L_k \\ &= \nu_{i_0} \pi_{i_0, i_1} \dots \pi_{i_{k-2}, i} \pi_{i, j} b_{i_0}^{Y_0} \dots b_i^{Y_{k-1}} b_j^{Y_k} \\ &= \mathbb{P}[X_0 = i_0, \dots, X_{k-2} = i_{k-2}, X_{k-1} = i \mid Y_0, \dots, Y_{k-1}] L_{k-1} \pi_{i, j} b_j^{Y_k} \end{aligned}$$

pour tout  $i, j \in E$  et tout  $i_0, \dots, i_{k-2} \in E$   
 en sommant par rapport à  $i_0, \dots, i_{k-2} \in E$ , on obtient

$$\begin{aligned} &\mathbb{P}[X_{k-1} = i, X_k = j \mid Y_0, \dots, Y_k] L_k \\ &= \mathbb{P}[X_{k-1} = i \mid Y_0, \dots, Y_{k-1}] L_{k-1} \pi_{i, j} b_j^{Y_k} = p_{k-1}^i \pi_{i, j} b_j^{Y_k} \end{aligned}$$

pour tout  $i, j \in E$ , et il suffit de sommer par rapport à  $i \in E$  □







○○○○○○○○○

○

○○○

○○○○○○○○○

○

○○○○○

○○○○○●○○○○○○○

○○○○○○○○○○○○○○○○○○○○

○○○○○○○○○○○○○○○○○○○○

○○○○○○○○○○○○○○○○○○○○

**Proposition** la suite  $\{\bar{p}_k\}$  vérifie l'équation récurrente suivante :

► dans le cas *symbolique*

$$\bar{p}_k^j = \frac{1}{c_k} \left[ \sum_{i \in E} \bar{p}_{k-1}^i \pi_{i,j} \right] b_j^{Y_k} \quad \text{pour tout } j \in E$$

avec la condition initiale :  $\bar{p}_0^i = \frac{1}{c_0} \nu_i b_i^{Y_0}$  pour tout  $i \in E$

où les constantes de normalisation sont définies par

$$c_k = \sum_{i,j \in E} \bar{p}_{k-1}^i \pi_{i,j} b_j^{Y_k} \quad \text{et} \quad c_0 = \sum_{i \in E} \nu_i b_i^{Y_0}$$



**Remarque** ce résultat énoncé composante–par–composante peut être aussi formulé pour la variable forward normalisée vue comme un *vecteur–ligne*

- ▶ dans le cas *symbolique*

$$\bar{p}_k = \frac{1}{c_k} \bar{p}_{k-1} \pi B^{Y_k} \quad \text{et} \quad \bar{p}_0 = \frac{1}{c_0} \nu B^{Y_0}$$

où les constantes de normalisation sont définies par

$$c_k = \bar{p}_{k-1} \pi b^{Y_k} \quad \text{et} \quad c_0 = \nu b^{Y_0}$$

- ▶ et dans le cas *numérique*

$$\bar{p}_k = \frac{1}{c_k} \bar{p}_{k-1} \pi G(Y_k) \quad \text{et} \quad \bar{p}_0 = \frac{1}{c_0} \nu G(Y_0)$$

où les constantes de normalisation sont définies par

$$c_k = \bar{p}_{k-1} \pi g(Y_k) \quad \text{et} \quad c_0 = \nu g(Y_0)$$

**Remarque** la suite  $\{\log L_k\}$  vérifie l'équation récurrente suivante : dans le cas *symbolique* et dans le cas *numérique*

$$\log L_k = \log L_{k-1} + \log c_k$$

avec la condition initiale

$$\log L_0 = \log c_0$$

et en itérant

$$\log L_n = \sum_{k=0}^n \log c_k$$

**Preuve** on considère uniquement le cas *symbolique* : en utilisant l'équation forward (F-sym), on obtient

$$\bar{p}_k^j = \frac{1}{L_k} p_k^j = \frac{1}{L_k} \left[ \sum_{i \in E} p_{k-1}^i \pi_{i,j} \right] b_j^{Y_k} = \frac{L_{k-1}}{L_k} \left[ \sum_{i \in E} \bar{p}_{k-1}^i \pi_{i,j} \right] b_j^{Y_k}$$

pour tout  $j \in E$ , et nécessairement

$$\frac{L_k}{L_{k-1}} = \sum_{i,j \in E} \bar{p}_{k-1}^i \pi_{i,j} b_j^{Y_k} = c_k$$

en utilisant la condition initiale de l'équation forward (F-sym)

$$\bar{p}_0^i = \frac{1}{L_0} p_0^i = \frac{1}{L_0} \nu_i b_i^{Y_0}$$

pour tout  $i \in E$ , et nécessairement

$$L_0 = \sum_{i \in E} \nu_i b_i^{Y_0} = c_0 \quad \square$$













○○○○○○○○○○

○

○○○

○○○○○○○○○○

○

○○○○○

○○○○○○○○○○○○○○○○

○○○○○●○○○○○○○○○○○○○○○○

○○

**Remarque** ce résultat énoncé composante–par–composante peut être aussi formulé pour la variable backward vue comme un *vecteur-colonne*

- ▶ dans le cas *symbolique*

$$v_{k-1} = \pi B^{Y_k} v_k \quad \text{et} \quad v_n \equiv 1$$

- ▶ et dans le cas *numérique*

$$v_{k-1} = \pi G(Y_k) v_k \quad \text{et} \quad v_n \equiv 1$$







**Corollaire** la distribution de probabilité conditionnelle de l'état présent  $X_k$  sachant toutes les observations  $(Y_0, \dots, Y_n)$  est donnée par :

$$\mathbb{P}[X_k = i \mid Y_0, \dots, Y_n] = \frac{1}{L_n} q_k^i \quad \text{pour tout } i \in E$$

avec la définition

$$q_k^i = p_k^i v_k^i \quad \text{pour tout } i \in E$$

**Remarque** on vérifie que les constantes de normalisation

$$\sum_{i,j \in E} p_{k-1}^i \pi_{i,j} b_j^{Y_k} v_k^j = \sum_{j \in E} \left[ \sum_{i \in E} p_{k-1}^i \pi_{i,j} \right] b_j^{Y_k} v_k^j = \sum_{j \in E} p_k^j v_k^j = L_n$$

et

$$\sum_{i \in E} q_k^i = \sum_{i \in E} p_k^i v_k^i = L_n$$

ne dépendent pas de l'instant considéré, et s'interprètent comme la vraisemblance du modèle sachant les observations  $(Y_0, \dots, Y_n)$



**Preuve de la Proposition** on considère uniquement le cas *symbolique* :  
fixer la transition entre les instants  $(k - 1)$  et  $k$  permet d'effectuer une coupure entre le passé jusqu'à l'instant  $(k - 2)$  et le futur à partir de l'instant  $(k + 1)$   
on se ramène à la distribution de probabilité conditionnelle des états cachés successifs sachant les observations, puis on marginalise et on utilise l'identité

$$\begin{aligned}
& \mathbb{P}[X_0 = i_0, \dots, X_{k-2} = i_{k-2}, X_{k-1} = i, \\
& X_k = j, X_{k+1} = i_{k+1}, \dots, X_n = i_n \mid Y_0, \dots, Y_n] L_n \\
&= \nu_{i_0} \pi_{i_0, i_1} \dots \pi_{i_{k-2}, i} \pi_{i, j} \pi_{j, i_{k+1}} \dots \pi_{i_{n-1}, i_n} \\
& b_{i_0}^{Y_0} \dots b_{i_{k-2}}^{Y_{k-2}} b_i^{Y_{k-1}} b_j^{Y_k} b_{i_{k+1}}^{Y_{k+1}} \dots b_{i_n}^{Y_n}
\end{aligned}$$

obtenue avec la méthode élémentaire, de sorte que





○○○○○○○○○

○

○○○

○○○○○○○○○

○

○○○○○

○○○○○○○○○○○○○○○

○○○○○○○○○○○○○●○○○○○○○○○

○○○○○○○○○○○○○○○○○○○○○○○○○○○○○○○○

Remarque avec cette normalisation de la variable backward, la distribution de probabilité conditionnelle de l'état  $X_k$  sachant les observations  $(Y_0, \dots, Y_n)$  s'exprime comme

$$\mathbb{P}[X_k = i \mid Y_0, \dots, Y_n] = \bar{p}_k^i \bar{v}_k^i = \bar{q}_k^i \quad \text{pour tout } i \in E$$



oooooooo

o  
oo  
oooooooo

o  
oooo  
oooooooooooooooooooo  
oooooooooooooooooooo●oooooooo

oo

Remarque ce résultat énoncé composante–par–composante peut être aussi formulé pour la variable backward normalisée vue comme un *vecteur–colonne*

▶ dans le cas *symbolique*

$$\bar{v}_{k-1} = \frac{1}{c_k} \pi B^{Y_k} \bar{v}_k \quad \text{et} \quad \bar{v}_n \equiv 1$$

▶ et dans le cas *numérique*

$$\bar{v}_{k-1} = \frac{1}{c_k} \pi G(Y_k) \bar{v}_k \quad \text{et} \quad \bar{v}_n \equiv 1$$

où les constantes de normalisation sont celles déjà définies pour la normalisation de la variable forward



**Remarque** on remarque que

$$\frac{1}{L_n} p_{k-1}^i v_k^j = \frac{L_{k-1}}{L_n} \bar{p}_{k-1}^i \frac{L_n}{L_k} \bar{v}_k^j = \frac{1}{c_k} \bar{p}_{k-1}^i \bar{v}_k^j \quad \text{pour tout } i, j \in E$$

et en reportant cette identité dans les expressions obtenues plus haut, on vérifie que la distribution de probabilité conditionnelle de la transition  $(X_{k-1}, X_k)$  sachant les observations  $(Y_0, \dots, Y_n)$  s'exprime

▶ dans le cas *symbolique* comme

$$\mathbb{P}[X_{k-1} = i, X_k = j \mid Y_0, \dots, Y_n] = \frac{1}{c_k} \bar{p}_{k-1}^i \pi_{i,j} b_j^{Y_k} \bar{v}_k^j$$

pour tout  $i, j \in E$

▶ et dans le cas *numérique* comme

$$\mathbb{P}[X_{k-1} = i, X_k = j \mid Y_0, \dots, Y_n] = \frac{1}{c_k} \bar{p}_{k-1}^i \pi_{i,j} g_j(Y_k) \bar{v}_k^j$$

pour tout  $i, j \in E$









○○○○○○○○○

○  
○○○  
○○○○○○○○○○  
○○○○○  
○○○○○○○○○○○○○○○  
○○○○○○○○○○○○○○○○○○

○○○●○○○○○○○○○○○○○○○○○○○○○○○○○○○○○○○○○○○○○○

il peut arriver que la suite  $(X_0^{\text{LMAP}}, \dots, X_n^{\text{LMAP}})$  ainsi générée soit incohérente avec le modèle, dans le sens suivant : il peut arriver que l'on obtienne  $X_{k-1}^{\text{LMAP}} = i$  et  $X_k^{\text{LMAP}} = j$  pour deux instants successifs, alors que  $\pi_{i,j} = 0$  pour cette même paire  $(i, j)$ , ce qui signifie que la transition de l'état  $i$  vers l'état  $j$  est juste impossible pour le modèle pour cette raison, on utilise plutôt un autre estimateur, appelé estimateur *trajectoriel* du *maximum a posteriori*, défini par

$$(X_0^{\text{MAP}}, \dots, X_n^{\text{MAP}}) = \operatorname{argmax}_{i_0, \dots, i_n \in E} \mathbb{P}[X_0 = i_0, \dots, X_n = i_n \mid Y_0, \dots, Y_n]$$

et qui minimise la probabilité de l'erreur d'estimation de la suite des états cachés sachant les observations  $(Y_0, \dots, Y_n)$

il n'est bien sûr pas possible d'effectuer cette maximisation de manière exhaustive, en énumérant toutes les  $|E|^{n+1}$  trajectoires possibles : le calcul efficace de cet estimateur est fourni par un algorithme de programmation dynamique, appelé *algorithme de Viterbi*



○○○○○○○○○○

○  
○○○  
○○○○○○○○○○○  
○○○○○  
○○○○○○○○○○○○○○○○○○○○  
○○○○○○○○○○○○○○○○○○○○

○○○○○●○○

## programmation dynamique

si la suite  $(i_0^*, \dots, i_k^*)$  atteint le maximum de la fonction

$$(i_0, \dots, i_k) \mapsto \mathbb{P}[X_0 = i_0, \dots, X_k = i_k \mid Y_0, \dots, Y_k]$$

alors nécessairement  $i_k^*$  atteint le maximum de la fonction

$$i \mapsto \max_{i_0, \dots, i_{k-1} \in E} \mathbb{P}[X_0 = i_0, \dots, X_{k-1} = i_{k-1}, X_k = i \mid Y_0, \dots, Y_k]$$

ce qui justifie d'introduire la fonction *valeur*

$$V_k^i = \max_{i_0, \dots, i_{k-1} \in E} \mathbb{P}[X_0 = i_0, \dots, X_{k-1} = i_{k-1}, X_k = i \mid Y_0, \dots, Y_k] L_k$$

pour tout  $i \in E$

**Théorème** la suite  $\{V_k\}$  vérifie la récurrence suivante :

- ▶ dans le cas *symbolique*

$$V_k^j = \max_{i \in E} [V_{k-1}^i \pi_{i,j}] b_j^{Y_k} \quad \text{pour tout } j \in E \quad (\text{V-sym})$$

avec la condition initiale :  $V_0^i = \nu_i b_i^{Y_0}$  pour tout  $i \in E$

- ▶ et dans le cas *numérique*

$$V_k^j = \max_{i \in E} [V_{k-1}^i \pi_{i,j}] g_j(Y_k) \quad \text{pour tout } j \in E \quad (\text{V-num})$$

avec la condition initiale :  $V_0^i = \nu_i g_i(Y_0)$  pour tout  $i \in E$

la suite  $\{V_k\}$  est instrumentale et permet de définir à chaque instant et pour tout état  $j \in E$ , l'indice

$$I_{k-1}(j) = \operatorname{argmax}_{i \in E} [V_{k-1}^i \pi_{i,j}]$$

qui s'interprète comme un pointeur vers un état à l'instant précédent













○○○○○○○○○

○  
○○○  
○○○○○○○○○○  
○○○○○  
○○○○○○○○○○○○○○○○○○○○  
○○○○○○○○○○○○○○○○○○○○

○○○○○○○○○○○○○○●○○○ ○○○○○○○○○○○○○○○○○○○

c'est-à-dire que  $i_{k-1}^*$  atteint le maximum de la fonction

$$i \mapsto V_{k-1}^i \pi_{i,i_k^*}$$

en d'autres termes

$$i_{k-1}^* = \operatorname{argmax}_{i \in E} [V_{k-1}^i \pi_{i,i_k^*}] = I_{k-1}(i_k^*) \quad \square$$

○○○○○○○○○

○  
○○○  
○○○○○○○○○○  
○○○○○  
○○○○○○○○○○○○○○○  
○○○○○○○○○○○○○○○○○○○○

○○○○○○○○○○○○○○○○○○○●○○○○○○○○○○○○○○○○○○○

classification bayésienne

modèles de Markov cachés

équations forward / backward de Baum

algorithme de Viterbi

re-estimation de Baum-Welch

détection de changement

○○○○○○○○○○

○  
○○○  
○○○○○○○○○○○  
○○○○○  
○○○○○○○○○○○○○○○○○○○○  
○○○○○○○○○○○○○○○○○○○○

○○○○○○○○○○○○○○○○○○○○●○○○○○○○○○○○○○○○○○○○○

jusqu'ici, l'accent a porté sur l'estimation d'un état caché ou de la suite des états cachés successifs, à partir d'une suite d'observations et pour un modèle *donné*

l'objectif ici est d'*identifier* le modèle, c'est-à-dire d'estimer les paramètres caractéristiques du modèle, à partir d'une suite d'observations, et le point de vue adopté est celui de l'estimation par *maximum de vraisemblance*

---

cas symbolique

dans le cas *symbolique*, la fonction de vraisemblance du modèle  $\mathbf{M} = (\nu, \pi, b)$  admet l'expression

$$L_n = \sum_{i_0, \dots, i_n \in E} \nu_{i_0} \pi_{i_0, i_1} \cdots \pi_{i_{n-1}, i_n} b_{i_0}^{Y_0} \cdots b_{i_n}^{Y_n}$$

obtenue avec la méthode élémentaire, et on se propose d'étudier un algorithme itératif pour *maximiser* la fonction de vraisemblance  $L_n$  par rapport aux paramètres  $(\nu, \pi, b)$  du modèle : soit  $\mathbf{M}' = (\nu', \pi', b')$  un autre modèle, pour lequel la fonction de vraisemblance prend la valeur

$$L'_n = \sum_{i_0, \dots, i_n \in E} \nu'_{i_0} \pi'_{i_0, i_1} \cdots \pi'_{i_{n-1}, i_n} b'_{i_0}^{Y_0} \cdots b'_{i_n}^{Y_n}$$





○○○○○○○○○○

○  
○○○  
○○○○○○○○○○○  
○○○○○  
○○○○○○○○○○○○○○○○○○○○  
○○○○○○○○○○○○○○○○○○○○

○○○○○○○○○○○○○○○○○○○○○○○○○○○○○○○○○○●○○○○○○○○○○○○○○○○○○○○

le (logarithme du) rapport de vraisemblance entre le modèle  $M$  et le modèle  $M'$  est donc minoré par

$$Q_n = \mathbb{E}' \left[ \log \frac{\nu_{X_0} \pi_{X_0, X_1} \cdots \pi_{X_{n-1}, X_n} b_{X_0}^{Y_0} \cdots b_{X_n}^{Y_n}}{\nu'_{X_0} \pi'_{X_0, X_1} \cdots \pi'_{X_{n-1}, X_n} b'_{X_0}^{Y_0} \cdots b'_{X_n}^{Y_n}} \mid Y_0, \dots, Y_n \right]$$

qui s'annule quand le modèle  $M$  coïncide avec le modèle  $M'$   
 maximiser  $Q_n$  par rapport aux paramètres  $(\nu, \pi, b)$  du modèle  $M$  garantit donc que la vraisemblance du modèle qui atteint le maximum de  $Q_n$  sera supérieure à la vraisemblance  $L'_n$  du modèle courant  $M'$   
 les formules de re-estimation de Baum-Welch permettent de trouver explicitement les paramètres du nouveau modèle en fonction des paramètres  $(\nu', \pi', b')$  du modèle courant  $M'$   
 en répétant cette procédure, on construit une suite de modèles de vraisemblance croissante, et idéalement cette suite converge vers un modèle qui atteint le maximum de la fonction de vraisemblance

○○○○○○○○○○

○

○○○  
○○○○○○○○○○

○

○○○○○  
○○○○○○○○○○○○○○○○  
○○○○○○○○○○○○○○○○○○○○○○○○○○○○○○

○○○○○○○○○○○○○○○○○○○○○○○○○○○○○○○●○○○○○○○○○○○○○○○○○○

**Théorème** l'algorithme itératif pour l'estimation par maximum de vraisemblance des paramètres du modèle au vu des observations  $(Y_0, \dots, Y_n)$ , est donné par les formules explicites de re-estimation

$$\nu_i = \bar{p}'_0{}^i \bar{v}'_0{}^i \quad \text{et} \quad \pi'_{i,j} = \pi'_{i,j} \frac{\sum_{k=1}^n \frac{1}{c'_k} \bar{p}'_{k-1}{}^i b'_j{}^{Y_k} \bar{v}'_k{}^j}{\sum_{k=1}^n \bar{p}'_{k-1}{}^i \bar{v}'_{k-1}{}^i}$$

et

$$b'_i{}^\ell = \frac{\sum_{k=0}^n 1_{(Y_k = \ell)} \bar{p}'_k{}^i \bar{v}'_k{}^i}{\sum_{k=0}^n \bar{p}'_k{}^i \bar{v}'_k{}^i}$$

pour tout  $i, j \in E$  et tout  $\ell \in O$ , où les deux suites  $\{\bar{p}'_k\}$  et  $\{\bar{v}'_k\}$  sont les solutions normalisées des équations forward et backward respectivement, pour les valeurs  $(\nu', \pi', b')$  des paramètres

**Remarque** concrètement, si  $\mathbf{M}_{s-1} = (\nu_{s-1}, \pi_{s-1}, b_{s-1})$  désigne le modèle courant à l'étape  $(s - 1)$  de l'algorithme, alors

- ▶ pour les valeurs  $(\nu', \pi', b') = (\nu_{s-1}, \pi_{s-1}, b_{s-1})$  des paramètres, on calcule les solutions normalisées  $\{\bar{p}'_k\}$  et  $\{\bar{v}'_k\}$  des équations forward et backward respectivement
- ▶ on calcule les paramètres  $(\nu_s, \pi_s, b_s) = (\nu, \pi, b)$  grâce aux formules de re-estimation

ce qui définit le nouveau modèle  $\mathbf{M}_s = (\nu_s, \pi_s, b_s)$  à l'étape suivante  $s$  de l'algorithme

○○○○○○○○○○

○

○○○

○○○○○○○○○○

○

○○○○○

○○○○○○○○○○○○○○○○○○

○○○○○○○○○○○○○○○○○○○○○○○○○○○○

○○○○○○○○○○○○○○○○○○○○○○○○○○○○

○○○○○○○●○○○○○○○○○○○○○○○○○○○○

Preuve on remarque que

$$Q_n = \mathbb{E}' \left[ \log \frac{\nu_{X_0} \pi_{X_0, X_1} \cdots \pi_{X_{n-1}, X_n} b_{X_0}^{Y_0} \cdots b_{X_n}^{Y_n}}{\nu'_{X_0} \pi'_{X_0, X_1} \cdots \pi'_{X_{n-1}, X_n} b'^{Y_0}_{X_0} \cdots b'^{Y_n}_{X_n}} \mid Y_0, \dots, Y_n \right]$$

$$= \mathbb{E}' \left[ \log \nu_{X_0} + \sum_{k=1}^n \log \pi_{X_{k-1}, X_k} + \sum_{k=0}^n \log b_{X_k}^{Y_k} \mid Y_0, \dots, Y_n \right] + \text{cste}$$

$$= \sum_{i \in E} \mathbb{P}' [X_0 = i \mid Y_0, \dots, Y_n] \log \nu_i$$

$$+ \sum_{i, j \in E} \left\{ \sum_{k=1}^n \mathbb{P}' [X_{k-1} = i, X_k = j \mid Y_0, \dots, Y_n] \right\} \log \pi_{i,j}$$

$$+ \sum_{i \in E} \sum_{\ell \in \mathcal{O}} \left\{ \sum_{k=0}^n 1_{(Y_k = \ell)} \mathbb{P}' [X_k = i \mid Y_0, \dots, Y_n] \right\} \log b_i^\ell + \text{cste}$$

○○○○○○○○○○

○  
○○○  
○○○○○○○○○○○  
○○○○○  
○○○○○○○○○○○○○○○○○○○○  
○○○○○○○○○○○○○○○○○○○○

○○○○○○○○○○○○○○○○○○○○○○○○○○○○○○●○○○○○○○○○○

on rappelle également les expressions obtenues pour les distributions conditionnelles de l'état  $X_k$  ou de la transition  $(X_{k-1}, X_k)$  sachant les observations  $(Y_0, \dots, Y_n)$

$$\mathbb{P}'[X_k = i \mid Y_0, \dots, Y_n] = \bar{p}'_k{}^i \bar{v}'_k{}^i \quad \text{pour tout } i \in E$$

et

$$\mathbb{P}'[X_{k-1} = i, X_k = j \mid Y_0, \dots, Y_n] = \frac{1}{c'_k} \bar{p}'_{k-1}{}^i \pi'_{i,j} b'_j{}^{Y_k} \bar{v}'_k{}^j$$

pour tout  $i, j \in E$ , et on en déduit que

$$\begin{aligned} Q_n &= \sum_{i \in E} \bar{p}'_0{}^i \bar{v}'_0{}^i \log \nu_i \\ &+ \sum_{i,j \in E} \left\{ \sum_{k=1}^n \frac{1}{c'_k} \bar{p}'_{k-1}{}^i \pi'_{i,j} b'_j{}^{Y_k} \bar{v}'_k{}^j \right\} \log \pi_{i,j} \\ &+ \sum_{i \in E} \sum_{\ell \in O} \left\{ \sum_{k=0}^n 1_{(Y_k = \ell)} \bar{p}'_k{}^i \bar{v}'_k{}^i \right\} \log b_i^\ell + \text{cste} \end{aligned}$$

○○○○○○○○○○

○  
○○○  
○○○○○○○○○○○  
○○○○○  
○○○○○○○○○○○○○○○○○○○○  
○○○○○○○○○○○○○○○○○○○○

○○○○○○○○○○○○○○○○○○○○○○○○○○○○○○●○○○○○○○○

la maximisation par rapport aux paramètres  $(\nu, \pi, b)$  sous les contraintes d'égalité

$$\sum_{i \in E} \nu_i = 1 \quad \sum_{j \in E} \pi_{i,j} = 1 \quad \text{et} \quad \sum_{\ell \in O} b_i^\ell = 1 \quad \text{pour tout } i \in E$$

est explicite, et on obtient les formules de re-estimation

$$\nu_i = \bar{p}_0^i \bar{v}_0^i \quad \text{et} \quad \pi_{i,j} = \pi'_{i,j} \frac{\sum_{k=1}^n \frac{1}{C'_k} \bar{p}_{k-1}^i b_j^{Y_k} \bar{v}_k^j}{\sum_{k=1}^n \bar{p}_{k-1}^i \bar{v}_{k-1}^i}$$

et

$$b_i^\ell = \frac{\sum_{k=0}^n 1(Y_k = \ell) \bar{p}_k^i \bar{v}_k^i}{\sum_{k=0}^n \bar{p}_k^i \bar{v}_k^i}$$

pour tout  $i, j \in E$  et tout  $\ell \in O$

○○○○○○○○○○

○  
○○○  
○○○○○○○○○○○  
○○○○○  
○○○○○○○○○○○○○○○○○○○○  
○○○○○○○○○○○○○○○○○○○○

○○○○○○○○○○○○○○○○○○○○○○○○○○○○○○●○○○○○○○○

## cas numérique

dans le cas *numérique*, on s'intéresse au cas des densités d'émission gaussiennes caractérisées par la donnée d'une famille *finie*  $h = (h_i)$  de vecteurs de  $\mathbb{R}^d$ , et d'une famille *finie*  $R = (R_i)$  de matrices de covariance inversibles, c'est-à-dire

$$g_i(y) = g(h_i, R_i, y) = \frac{1}{\sqrt{\det(2\pi R_i)}} \exp\left\{-\frac{1}{2} (y - h_i)^* R_i^{-1} (y - h_i)\right\}$$

la fonction de vraisemblance du modèle  $\mathbf{M} = (\nu, \pi, h, R)$  admet l'expression

$$L_n = \sum_{i_0, \dots, i_n \in E} \nu_{i_0} \pi_{i_0, i_1} \cdots \pi_{i_{n-1}, i_n} g_{i_0}(Y_0) \cdots g_{i_n}(Y_n)$$

obtenue avec la méthode élémentaire, et on se propose d'étudier un algorithme itératif pour *maximiser* la fonction de vraisemblance  $L_n$  par rapport aux paramètres  $(\nu, \pi, h, R)$  du modèle : soit  $\mathbf{M}' = (\nu', \pi', h', R')$  un autre modèle, pour lequel la fonction de vraisemblance prend la valeur

$$L'_n = \sum_{i_0, \dots, i_n \in E} \nu'_{i_0} \pi'_{i_0, i_1} \cdots \pi'_{i_{n-1}, i_n} g'_{i_0}(Y_0) \cdots g'_{i_n}(Y_n)$$

○○○○○○○○○○

○  
○○○  
○○○○○○○○○○○  
○○○○○  
○○○○○○○○○○○○○○○○○○○○  
○○○○○○○○○○○○○○○○○○○○○○○○○○○○○○

○○○○○○○○○○○○○○○○○○○○○○○○○○○○○○●○○○○○○○○

en procédant comme dans le cas *symbolique*, le (logarithme du) rapport de vraisemblance entre le modèle  $M$  et le modèle  $M'$  est minoré par

$$Q_n = \mathbb{E}' \left[ \log \frac{\nu_{X_0} \pi_{X_0, X_1} \cdots \pi_{X_{n-1}, X_n} g_{X_0}(Y_0) \cdots g_{X_n}(Y_n)}{\nu'_{X_0} \pi'_{X_0, X_1} \cdots \pi'_{X_{n-1}, X_n} g'_{X_0}(Y_0) \cdots g'_{X_n}(Y_n)} \mid Y_0, \dots, Y_n \right]$$

qui s'annule quand le modèle  $M$  coïncide avec le modèle  $M'$   
 maximiser  $Q_n$  par rapport aux paramètres  $(\nu, \pi, h, R)$  du modèle  $M$   
 garantit donc que la vraisemblance du modèle qui atteint le maximum de  $Q_n$  sera supérieure à la vraisemblance  $L'_n$  du modèle courant  $M'$   
 les formules de re-estimation de Baum-Welch permettent de trouver explicitement les paramètres du nouveau modèle en fonction des paramètres  $(\nu', \pi', h', R')$  du modèle courant  $M'$   
 en répétant cette procédure, on construit une suite de modèles de vraisemblance croissante, et idéalement cette suite converge vers un modèle qui atteint le maximum de la fonction de vraisemblance



○○○○○○○○○○

○  
○○○  
○○○○○○○○○○○  
○○○○○  
○○○○○○○○○○○○○○○○○○○○  
○○○○○○○○○○○○○○○○○○○○

○○○○○○○○○○○○○○○○○○○○○○○○○○○○○○●○○○○○○○○○○

**Théorème** dans le cas *numérique* avec des densités d'émission gaussiennes, l'algorithme itératif pour l'estimation par maximum de vraisemblance des paramètres du modèle au vu des observations  $(Y_0, \dots, Y_n)$ , est donné par les formules explicites de re-estimation

$$\nu_i = \bar{p}'_0 \bar{v}'_0 \quad \text{et} \quad \pi_{i,j} = \pi'_{i,j} \frac{\sum_{k=1}^n \frac{1}{c'_k} \bar{p}'_{k-1} g'_j(Y_k) \bar{v}'_k{}^j}{\sum_{k=1}^n \bar{p}'_{k-1} \bar{v}'_{k-1}{}^i}$$

et

$$h_i = \frac{\sum_{k=0}^n Y_k \bar{p}'_k{}^i \bar{v}'_k{}^i}{\sum_{k=0}^n \bar{p}'_k{}^i \bar{v}'_k{}^i} \quad \text{et} \quad R_i = \frac{\sum_{k=0}^n (Y_k - h_i) (Y_k - h_i)^* \bar{p}'_k{}^i \bar{v}'_k{}^i}{\sum_{k=0}^n \bar{p}'_k{}^i \bar{v}'_k{}^i}$$

pour tout  $i, j \in E$ , où les deux suites  $\{\bar{p}'_k\}$  et  $\{\bar{v}'_k\}$  sont les solutions normalisées des équations forward et backward respectivement, pour les valeurs  $(\nu', \pi', h', R')$  des paramètres

○○○○○○○○○○

○  
○○○  
○○○○○○○○○○○  
○○○○○  
○○○○○○○○○○○○○○○○○○○○  
○○○○○○○○○○○○○○○○○○○○

○○○●○○○○○○○○○○

**Remarque** concrètement, si  $\mathbf{M}_{s-1} = (\nu_{s-1}, \pi_{s-1}, h_{s-1}, R_{s-1})$  désigne le modèle courant à l'étape  $(s-1)$  de l'algorithme, alors

- ▶ pour les valeurs  $(\nu', \pi', h', R') = (\nu_{s-1}, \pi_{s-1}, h_{s-1}, R_{s-1})$  des paramètres, on calcule les solutions normalisées  $\{\bar{p}'_k\}$  et  $\{\bar{v}'_k\}$  des équations forward et backward respectivement
- ▶ on calcule les paramètres  $(\nu_s, \pi_s, h_s, R_s) = (\nu, \pi, h, R)$  grâce aux formules de re-estimation

ce qui définit le nouveau modèle  $\mathbf{M}_s = (\nu_s, \pi_s, h_s, R_s)$  à l'étape suivante  $s$  de l'algorithme



○○○○○○○○○○

○

○○○

○○○○○○○○○○

○

○○○○○

○○○○○○○○○○○○○○○○○○○○

○○○○○○○○○○○○○○○○○○○○

○○○○○○○○○○○○○○○○○○○○○○

○○○○○○○○○○○○○○○○○○○○○○

○○○○○○○○○○○○○○○○○○○○○○

○○○○○○○○○○○○○○○○○○○○○○●○○○

on remarque que

$$\begin{aligned}\log g_i(y) &= -\frac{1}{2} \log \det R_i - \frac{1}{2} (y - h_i)^* R_i^{-1} (y - h_i) + \text{cste} \\ &= \frac{1}{2} \log \det M_i - \frac{1}{2} \text{trace}[(y - h_i)(y - h_i)^* M_i] + \text{cste}\end{aligned}$$

avec  $M_i = R_i^{-1}$  pour tout  $i \in E$  et tout  $y \in \mathbb{R}^d$

on rappelle également les expressions obtenues pour les distributions conditionnelles de l'état  $X_k$  ou de la transition  $(X_{k-1}, X_k)$  sachant les observations  $(Y_0, \dots, Y_n)$

$$\mathbb{P}'[X_k = i \mid Y_0, \dots, Y_n] = \bar{p}'_k{}^i \bar{v}'_k{}^i \quad \text{pour tout } i \in E$$

et

$$\mathbb{P}'[X_{k-1} = i, X_k = j \mid Y_0, \dots, Y_n] = \frac{1}{c'_k} \bar{p}'_{k-1}{}^i \pi'_{i,j} g'_j(Y_k) \bar{v}'_k{}^j$$

pour tout  $i, j \in E$



la maximisation par rapport aux paramètres  $(\nu, \pi, h, R)$  sous les contraintes d'égalité

$$\sum_{i \in E} \nu_i = 1 \quad \text{et} \quad \sum_{j \in E} \pi_{i,j} = 1 \quad \text{pour tout } i \in E$$

est explicite, et on obtient les formules de re-estimation

$$\nu_i = \bar{p}_0^i \bar{v}_0^i \quad \text{et} \quad \pi_{i,j} = \pi'_{i,j} \frac{\sum_{k=1}^n \frac{1}{c_k'} \bar{p}_{k-1}^i g_j'(Y_k) \bar{v}_k^j}{\sum_{k=1}^n \bar{p}_{k-1}^i \bar{v}_{k-1}^i}$$

et

$$h_i = \frac{\sum_{k=0}^n Y_k \bar{p}_k^i \bar{v}_k^i}{\sum_{k=0}^n \bar{p}_k^i \bar{v}_k^i} \quad \text{et} \quad R_i = \frac{\sum_{k=0}^n (Y_k - h_i) (Y_k - h_i)^* \bar{p}_k^i \bar{v}_k^i}{\sum_{k=0}^n \bar{p}_k^i \bar{v}_k^i}$$

pour tout  $i, j \in E$



classification bayésienne

modèles de Markov cachés

équations forward / backward de Baum

algorithme de Viterbi

re-estimation de Baum-Welch

détection de changement

on considère le problème de détecter au vu des observations  $(Y_0, \dots, Y_n)$  un (éventuel) changement dans le modèle  $M = (\nu, \pi, b)$  dans le cas *symbolique*, ou dans le modèle  $M = (\nu, \pi, g)$  dans le cas *numérique*, à un instant  $\tau$  inconnu compris entre l'instant initial  $0$  et l'instant final  $n$  (ou bien au-delà de l'instant final  $n$ )

- ▶ à l'instant  $0$ , la loi initiale est  $\nu^0 = (\nu_i^0)$
- ▶ jusqu'à l'instant  $\tau$ , i.e. entre l'instant initial  $0$  et l'instant  $\tau$ , le modèle est *nominal*, c'est-à-dire que la matrice de transition est  $\pi^0 = (\pi_{ij}^0)$  et les probabilités d'émission sont  $b^0 = (b_i^{l,0})$ , ou les densités d'émission sont  $g^0 = (g_i^0)$
- ▶ au-delà de l'instant  $\tau$ , i.e. entre l'instant  $\tau$  et l'instant final  $n$ , le modèle est *modifié*, c'est-à-dire que la matrice de transition est  $\pi = (\pi_{ij})$  et les probabilités d'émission sont  $b = (b_i^l)$ , ou les densités d'émission sont  $g = (g_i)$




oooooooo

o  
oo  
oooooooo

o  
oooo  
oooooooooooooooooooo  
oooooooooooooooooooooooooooo

oo







○○○○○○○○○

○  
○○○  
○○○○○○○○○○  
○○○○○  
○○○○○○○○○○○○○○○○○○○  
○○○○○○○○○○○○○○○○○○○

○○○○○○○○○○○○○○○○○○○○ ○○○○○○○○○○○○○○○○○○○○

propriété de dualité des variables forward et backward :

pour tout  $\tau = 0 \dots (n - 1)$ , la vraisemblance pour le modèle avec changement à l'instant  $\tau$ , peut être calculée comme

$$L_n(\tau) = \sum_{i \in E} p_n^i(\tau) = \sum_{i \in E} p_k^i(\tau) v_k^i(\tau)$$

où  $p_k(\tau) = (p_k^i(\tau))$  désigne la variable forward à un instant intermédiaire  $k$ , calculée en utilisant

- ▶ le modèle *nominal* depuis l'instant initial 0 et jusqu'à l'instant  $\tau$
- ▶ le modèle *modifié* à partir de l'instant  $\tau$  et jusqu'à l'instant final  $n$

et où  $v_k(\tau) = (v_k^i(\tau))$  désigne la variable backward à un instant intermédiaire  $k$ , calculée en utilisant

- ▶ le modèle *modifié* depuis l'instant initial  $n$  et jusqu'à l'instant  $\tau$
- ▶ le modèle *nominal* à partir de l'instant  $\tau$  et jusqu'à l'instant final 0







ce dernier schéma adapté permet d'évaluer la vraisemblance  $L_n(\tau)$  pour tous les instants de changement possibles  $\tau = 0, 1 \dots n$  en propageant deux équations seulement

- ▶ une équation forward utilisant le modèle *nominal* uniquement
- ▶ une équation backward utilisant le modèle *modifié* uniquement