

# A Tutorial on Hidden Markov Models and Selected Applications

in Speech Recognition


L.R. Rabiner, 1989, IEEE

# Plan

1. Caractérisation d'un HMM
2. Les trois problèmes de base des HMM
3. Discussion / Limites


# Modèles de Markov Cachés

- ▶ Données: Une série d'observations  $\mathbf{O} = O_1 O_2 O_3 \dots O_T$
- ▶ Modèle: Les données sont générées par un processus (une chaîne) de Markov sur des états  $\mathbf{Q} = q_1 q_2 q_3 \dots q_T$  (cachés car non observés).



## B. Éléments d'un HMM (p. 260)

- ▶ Les états cachés:
  - ▶ nombre d'états  $N$
  - ▶  $\mathbf{S} = \{S_1, S_2, \dots, S_N\}$
  - ▶ L'état au temps  $t$ :  $q_t$
- ▶ Les valeurs possibles pour  $O_t =$  un alphabet discret
  - ▶ nombre de symboles:  $M$
  - ▶  $\mathbf{V} = \{v_1, v_2, \dots, v_M\}$
- ▶ Les probabilités de transition entre états  $A = \{a_{ij}\}$ :  
 $a_{ij} = P(q_{t+1} = S_j | q_t = S_i)$
- ▶ Les probabilités d'émission  $B = \{b_j(k)\}$ :  
 $b_j(k) = P(O_t = v_k | q_t = S_j)$
- ▶ Les probabilités initiales:  
 $\pi_i = P(q_1 = S_i)$



# Présentation des trois problèmes

- Problème 1: Calcul de la vraisemblance** Etant donné une séquence d'observations  $\mathbf{O}$  et un HMM  $\lambda = (A, B, \pi)$ , comment calculer efficacement  $P(\mathbf{O}|\lambda)$  ?
- Problème 2: Détermination de la séquence optimale** Etant donné une séquence d'observations  $\mathbf{O}$  et le modèle  $\lambda$ , comment choisir la séquence  $\mathbf{Q}$  qui soit optimale (e.g. qui explique le mieux les observations) ?
- Problème 3: Estimation** Comment ajuster les paramètres  $\lambda$  pour maximiser  $P(\mathbf{O}|\lambda)$  ?

# Calcul de Vraisemblance: Solution naive

- ▶ Sachant une séquence d'état cachés  $\mathbf{Q}$ :

$$P(\mathbf{O}|\mathbf{Q}, \lambda) = \prod_{t=1}^T P(O_t|q_t, \lambda) = b_{q_1}(O_1).b_{q_2}(O_2) \dots b_{q_T}(O_T)$$

- ▶ La probabilité d'une séquence d'états cachés  $\mathbf{Q}$  est simplement:

$$P(\mathbf{Q}|\lambda) = \pi_{q_1} a_{q_1 q_2} a_{q_2 q_3} \dots a_{q_{T-1} q_T}$$

- ▶ Finalement:


$$P(\mathbf{O}|\lambda) = \sum_{\text{all } \mathbf{Q}} P(\mathbf{O}|\mathbf{Q}, \lambda)P(\mathbf{Q}|\lambda)$$

- ▶ Mais complexité en  $T.N^T$  : inefficace

# Calcul de Vraisemblance: Procédure Forward (p. 262)

Calcul des variables forward :

$$\alpha_t(i) = P(O_1, O_2, \dots, O_t, q_t = S_i | \lambda) \text{ pour } t \in [1..T]$$



1. Initialisation:

$$\alpha_1(i) = \pi_i b_i(O_1)$$

2. Induction:

$$\alpha_{t+1}(j) = \left[ \sum_{i=1}^N \alpha_t(i) a_{ij} \right] b_j(O_{t+1})$$

3. Termination:


$$P(\mathbf{O} | \lambda) = \sum_{i=1}^N \alpha_T(i)$$

Complexité:  $N^2 \cdot T$  au maximum

## Procédure Backward (p. 263)

Calcul des variables forward :

$$\beta_t(i) = P(O_{t+1}, O_{t+2}, \dots, O_T | q_t = S_i, \lambda) \text{ pour } t \in [1..T]$$



1. Initialisation:

$$\beta_T(i) = 1$$

2. Induction:

$$\beta_t(i) = \sum_{j=1}^N a_{ij} b_j(O_{t+1}) \beta_{t+1}(j)$$

Complexité:  $N^2 \cdot T$  au maximum



## Calcul de l'état le plus probable à chaque position

- ▶ A chaque position, on peut chercher l'état  $S_i$  qui maximise:

$$\gamma_t(i) = P(q_t = S_i | \mathbf{O}, \lambda)$$

$$\gamma_t(i) = \frac{\alpha_t(i)\beta_t(i)}{\sum_{i=1}^N \alpha_t(i)\beta_t(i)}$$

- ▶ Maximise le nombre d'états cachés “corrects” moyens.
- ▶ Problème: la séquence obtenue peut ne pas être valide

# Recherche de la séquence de probabilité maximale: Algorithme de Viterbi (p. 264)

On définit le score suivant:

$$\delta_t(i) = \max_{q_1, q_2, \dots, q_{t-1}} P(q_1 q_2 \dots q_t = S_i, O_1, O_2 \dots O_t | \lambda)$$

$\delta_t(i)$  est le score max (probabilité) pour une séquence qui prend en compte les observations jusqu'à  $t$  et qui arrive à l'état  $S_i$  en  $t$ .

1. Initialisation:

$$\delta_1(i) = \pi_i b_i(O_1) \quad \psi_1(i) = 0$$

2. Recurrence:

$$\delta_t(j) = \max_{1 \leq i \leq N} [\delta_{t-1}(i) a_{ij}] b_j(O_t) \quad \psi_t(j) = \operatorname{argmax} [\delta_{t-1}(i) a_{ij}]$$

3. Fin:


$$P^* = \max [\delta_T(i)] \quad q_T^* = \operatorname{argmax} [\delta_T(i)]$$

4. Backtracking:  $q_t^* = \psi_{t+1}(q_{t+1}^*)$

# Problème

- ▶ *By far the most difficult problem of HMMs is to determine a method to adjust the model parameters  $(A,B,\pi)$  to maximize the [likelihood]*
- ▶ Recherche d'un optimum local en utilisant l'algorithme de Baum-Welch (algorithme EM).
- ▶ Se calcule en utilisant les variables  $\alpha, \beta, \gamma$  précédentes, plus :

$$\xi_t(i, j) = P(q_t = S_i, q_{t+1} = S_j | \mathbf{O}, \lambda)$$



$$\xi_t(i, j) = \frac{\alpha_t(i) a_{ij} b_j(O_{t+1}) \beta_{t+1}(j)}{P(\mathbf{O} | \lambda)}$$

- ▶ Les détails d'implémentation dépendent du modèle (transitions constantes ou locales, comptage d'évènements ...) En résumé:

$\bar{\pi}_i =$  expected number of times in state  $S_i$  at time ( $t = 1$ )

$$\bar{a}_{ij} = \frac{\text{expected number of transitions from state } S_i \text{ to state } S_j}{\text{expected number of transitions from state } S_i}$$

$$b_j(\bar{k}) = \frac{\text{expected number of times in state } j \text{ and observing symbol } v_k}{\text{expected number of times in state } j}$$

qui se calculent conditionnellement aux valeurs courantes et permettent de les mettre à jour

# Conclusions

- ▶ Avec l'ensemble de ces résultats, il est possible d'implémenter l'estimation, l'utilisation d'un modèle HMM simple.
- ▶ Extensions sont nombreuses (cf. exposés suivants)
- ▶ Quelques HMM célèbres en génétique:
  - ▶ **Lander et Green (1987)**: Calculs de vraisemblance dans des pedigrees complexes. Etats Cachés: indicateurs de ségrégations. Observations: génotypes. Séquence: marqueurs le long des chromosomes. (CRIMAP)
  - ▶ **Li and Stephens (2003)** : Etats cachés: haplotypes connus. Etat observé: haplotype / génotype. (PHASE)
  - ▶ **Scheet et Stephens (2006)** (fastPHASE) ; **Browning's (2005 ...)** (Beagle): Etats cachés: groupes d'haplotypes locaux. Etats observés: haplotypes / génotypes.